

UNIVERSIDADE FEDERAL DO PARANÁ

RODRIGO MIKOSZ GONÇALVES

**MODELAGEM DE TENDÊNCIA A CURTO-PRAZO DA LINHA DE COSTA ATRAVÉS
DE DADOS GEODÉSICOS TEMPORAIS UTILIZANDO REGRESSÃO LINEAR,
ESTIMATIVA ROBUSTA E REDES NEURAIS ARTIFICIAIS**

CURITIBA
2010

RODRIGO MIKOSZ GONÇALVES

**MODELAGEM DE TENDÊNCIA A CURTO-PRAZO DA LINHA DE COSTA ATRAVÉS
DE DADOS GEODÉSICOS TEMPORAIS UTILIZANDO REGRESSÃO LINEAR,
ESTIMATIVA ROBUSTA E REDES NEURAIS ARTIFICIAIS**

Tese apresentada ao Programa de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientadores:

Prof^a. Dr^a. Claudia Pereira Krueger (UFPR)

Prof. Dr. Leandro dos Santos Coelho (PUC-PR/UFPR)

Prof. Dr. Bernhard Heck (KIT - Karlsruher Institut für Technologie, Alemanha)

CURITIBA
2010

Gonçalves, Rodrigo Mikosz

Modelagem de tendência a curto-prazo da linha de costa através de dados geodésicos temporais utilizando regressão linear, estimativa robusta e redes neurais artificiais / Rodrigo Mikosz Gonçalves. - Curitiba, 2010.

152 f. : il., color., tabs.

Tese (Doutorado) – Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas.

Orientadores: Claudia Pereira Krueger

Leandro dos Santos Coelho

Bernhard Heck

1. Costa. 2. Gerenciamento costeiro. 3. Fotogrametria aérea. 4. Redes neurais (Computação). I. Krueger, Claudia Pereira. II. Coelho, Leandro dos Santos. III. Heck, Bernhard. IV. Título. V. Universidade Federal do Paraná.

CDD 526.982

TERMO DE APROVAÇÃO


RODRIGO MIKOSZ GONÇALVES


"MODELAGEM PREDITIVA A CURTO-PRAZO DE MOVIMENTAÇÃO DE LINHA DE COSTA ATRAVÉS DE DADOS GEODÉSICOS TEMPORAIS UTILIZANDO REGRESSÃO LINEAR, ESTIMATIVA ROBUSTA E REDES NEURAIS ARTIFICIAIS"


Tese nº 68 aprovada como requisito parcial do grau de Doutor no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:



Prof. Dr. Leandro dos Santos Coelho
Pontifícia Universidade Católica do Paraná, PUC/PR


Prof. Dr. Gilberto Pessanha Ribeiro
Universidade Estadual do Rio de Janeiro, UERJ


Profª. Drª. Selma Regina Aranha Ribeiro
Universidade Estadual de Ponta Grossa, UEPG


Profª. Drª. Maria Teresinha Arns Steiner
Departamento de Matemática, UFPR


Prof. Dr. Carlos Roberto Soares
Centro de Estudos do Mar, UFPR


Prof. Dr. Quintino Dalmolin
Departamento de Geomática, UFPR

Curitiba, 25 de fevereiro de 2010.

*Aos meus pais Marli Maria Mikosz Gonçalves e
Luiz Fernando Mikosz Gonçalves*

AGRADECIMENTOS

Aos meus Professores e Orientadores: Dr^a. Cláudia Pereira Krueger, Dr. Leandro dos Santos Coelho e Dr. Bernhard Heck, pela oportunidade, ensinamentos, seriedade e competência.

À Universidade Federal do Paraná e ao Instituto de Geodésia da Universidade de Karlsruhe, pelas acolhedoras estruturas e suporte para pesquisa.

Ao professor Dr. Joseph Awange da Universidade Tecnológica de Curtin, Austrália, pela amizade, conselhos e colaboração com idéias para tese.

Ao suporte financeiro da CAPES e CNPq.

À minha família, meus pais Luiz Fernando e Marli, irmãos Marcelo, Simone e Assíria, a pequena sobrinha Carolina e o cunhado Afonso, pela força e união.

*" A grande estrela por 7 dias arderá,
Grande nuvem fará 2 Sóis aparecer,
O grande mastim toda a noite uivará,
Quando grande pontífice mudar de território."*

*"Vereis cedo e tarde fazer grandes mudanças,
Horrores extremos e vindicações,
Que a Lua assim conduzida pelo seu anjo,
O Céu aproxima-se das inclinações."*

*"Quando a falta do Sol então será,
No pleno do dia o monstro será visto.
De modo bem diverso se interpretará,
Careza não tem guarda, ninguém tal terá previsto."*

*" A lei do Sol e Vênus contendidos
Apropriando o espírito de profecia,
Nem um nem outro serão entendidos,
Pois o Sol se manterá a lei do grande Messias."*

Profecia de Nostradamus (1503-1556) para o ano de 2012

RESUMO

Monitorar e gerenciar a linha de costa é importante em áreas costeiras, mas ainda representa uma tarefa difícil. Conhecer a variabilidade da linha de costa é crucial para operações realizadas por cientistas costeiros, engenheiros e administradores públicos que necessitam de informações sobre a posição da linha da costa, no passado, presente e, possivelmente, onde irá estar no futuro. Primeiro, é necessário fornecer uma definição funcional de linha de costa e, em seguida, desenvolver uma técnica suficientemente sólida que permita identificar e extrair a posição espacial da linha de costa com base na fonte de dados disponíveis para seu estudo. As informações históricas usadas para uma análise de curto-prazo são dependentes das incertezas associadas com a coleta dos dados antigos. O principal problema que acontece no Brasil está em recuperar dados com informações históricas sobre levantamentos e mapeamentos do passado. Com o propósito de estudar a dinâmica espacial da linha de costa no litoral do Paraná tornou-se necessário reunir dados cartográficos e materiais provenientes da fotogrametria analógica. Estes dados se referem à extração das linhas de costa temporais para anos 1954, 1963, 1980, 1991 e 1997, em 6 km de extensão no litoral do município de Matinhos no estado do Paraná, Brasil. Usando esses dados fotogramétricos, e dados obtidos por receptores GPS (*Global Positioning System*) para 2001, 2002, 2005 e 2008 (como controle), efetuaram-se comparações e avaliações estatísticas aplicando três diferentes modelos de tendência para linha de costa, incluindo-se: estimativa robusta, redes neurais artificiais e regressão linear. Na parte experimental, alguns testes, mudando a matriz dos pesos, para o caso de regressão linear e estimativa robusta foram efetuados. Diferentes testes com as redes neurais artificiais foram organizados mudando alguns parâmetros como: arquitetura (rede neural parcialmente recorrente de Elman e *perceptron* multicamadas), número de neurônios nas camadas ocultas e algoritmos de treinamentos. Os melhores resultados estatísticos indicaram que o MAPE (*Mean Absolute Percentage Error*), quando comparados os resíduos entre a predição e a linha de costa de controle, são respectivamente 0,33% para a regressão linear, 0,14% para estimativa robusta e 0,28% para o caso da rede neural de Elman com o algoritmo de treinamento quase-Newton utilizando 10 neurônios na camada oculta. Em outra comparação simulando 50 anos no futuro verificaram-se diferenças de até 400 metros nas posições das linhas de costa preditas entre os modelos de regressão linear e estimativa robusta. Os resultados indicam a importância da escolha dos modelos de tendência para linha de costa e aplicabilidades neste caso específico de estudo.

Palavras chaves: mapeamento costeiro, modelagem preditiva, linha de costa, estimativa robusta, redes neurais artificiais.

ABSTRACT

Monitoring and management of shoreline is important along the coast but remains a difficult task. The shoreline variability is crucial for daily operations undertaken by coastal scientists, engineers, and public managers who require information on the position of the shoreline in the past, present and possibly where it will move in the future. First, it is necessary to provide a functional definition of the shoreline, and then proceed to develop a sufficiently robust technique that would enable the detection and positional extraction of the chosen shoreline feature within the available data source. The historical information used for a short-term analysis is always dependent on uncertainties associated with old data collection. The main difficulty that happens often in Brazil, is to obtain historical information about surveys and mapping from the past. With the proposal to study shoreline dynamics at Paraná coast it became necessary to find cartographic information about it, and some old material from analogue photogrammetry was found. These data, related to the years 1954, 1963, 1980, 1991 and 1997, were used for shoreline extraction in a 6 km section of Matinhos beach in the state of Paraná, Brazil. Using these photogrammetric data, and GPS (Global Positioning System) data for 2001, 2002, 2005 and 2008 (as control), this study aims to demonstrate a comparison and assessment between three different models of shoreline prediction: *robust parameter estimation*, *neural network* and *linear regression*. Some tests changing the weigh matrix for the case of linear regression and robust estimation were done. Different tests with neural network were organized setting the parameters like: architecture (Elman and feedforward backpropagation network), number of neuron in hidden layers and the training algorithms. The best statistics results shows the MAPE (Mean Absolute Percentage Error) when compared with the residuals between the prediction and the shoreline of control are respectively 0,33% for linear regression, 0,14% for robust estimation and 0,28% for the case of neural network with the Elman network using the quasi-Newton training function and 10 neurons in the hidden layer. Another comparison simulating 50 years in the future, shows differences reaching 400 m in positions of predictive shorelines between the linear regression and robust estimation. The results highlighting the importance of the model choice for predicting the shoreline and the applicability in this specific case of study.

Keywords: coastal mapping, predictive modeling, shoreline, robust estimation, artificial neural networks.

LISTA DE ILUSTRAÇÕES

FIGURA 1	-	LINHA DE COSTA E LINHA DE ÁGUA INSTANTÂNEA.....	29
FIGURA 2	-	PREVISÃO DE MARÉS <i>ONLINE</i> : GUARATUBA - 13/09/2008.....	30
FIGURA 3	-	PREAMAR E BAIXAMAR NO MUNICÍPIO DE MATINHOS, FOTOS TIRADAS EM 13/09/2008.....	30
FIGURA 4	-	DIFERENTES CONFIGURAÇÕES DA LINHA DE COSTA NA ÁREA DE ESTUDO (A) LIMITE ENTRE A VEGETEÇÃO E A PRAIA (B) LIMITE ENTRE A PRAIA E O CONTINENTE (CALÇADA).....	31
FIGURA 5	-	EXEMPLO DE LINHA DE COSTA PREDITA PARA 2060 NO TEXAS, ESTADOS UNIDOS DA AMÉRICA.....	34
FIGURA 6	-	RESSACA DE MATINHOS EM MAIO DE 2001	35
FIGURA 7	-	LOCALIZAÇÃO DO LITORAL PARANAENSE E DEMAIS REGIÕES NATURAIS DO PARANÁ.....	36
FIGURA 8	-	UNIDADES GEOMORFOLÓGICAS DA REGIÃO DO LITORAL PARANAENSE.....	37
FIGURA 9	-	EXEMPLO DE LINHA DE COSTA ENCONTRADAS EM MATINHOS: ROCHOSA E SEDIMENTAR	38
FIGURA 10	-	VESTIÁRIOS DESTINADOS À TROCA DE ROUPA PARA O BANHO DE MAR, CONSTRUÍDOS EM 1928	40
FIGURA 11	-	PRAIA DE MATINHOS, INÍCIO DA DÉCADA DE 1930.....	41
FIGURA 12	-	HOTEL BEIRA-MAR DE RAINOLDO SCHEFFER.....	41
FIGURA 13	-	FOTO AÉREA VERTICAL DE CAIOBÁ TOMADA EM 1953, (LINHA VERMELHA) TRAÇADO DA AVENIDA ATLÂNTICA, (LINHA AZUL) LINHA DE COSTA.....	42
FIGURA 14	-	EVOLUÇÃO DO PROBLEMA EROSIVO AO LONGO DA ORLA DO MUNICÍPIO DE MATINHOS	43

FIGURA 15	-	(a) CASAS DESTRUÍDAS PELA RESSACA DE MAIO, 2000 EM MATINHOS (b) COM A RELOCAÇÃO DAS CASAS VERIFICA-SE A RECOMPOSIÇÃO NATURAL DA PRAIA E DA DUNA FRONTAL EM 2004	44
FIGURA 16	-	EFEITOS DA RESSACA NA COSTA DE MATINHOS (MAIO, 2001)	44
FIGURA 17	-	FOTOGRAFIAS DA ÁREA DE ESTUDO DOS ANOS DE 2007 E 2008.....	45
FIGURA 18	-	FOTOS AÉREAS TEMPORAIS DO PORTO DE PARANAGUÁ, PARANÁ.....	46
FIGURA 19	-	IMAGEM CLASSIFICADA DE MATINHOS-PARANÁ.....	48
FIGURA 20	-	MODELO DIGITAL DO TERRENO E EXTRAÇÃO DE LINHAS OBTIDAS PELO LIDAR.....	49
FIGURA 21	-	DADOS OBTIDOS PELO LIDAR.....	50
FIGURA 22	-	LEVANTAMENTO RELATIVO CINEMÁTICO	51
FIGURA 23	-	CANDIDATA PARA A LINHA ESTIMADA DE REGRESSÃO	55
FIGURA 24	-	NEURÔNIO BIOLÓGICO	64
FIGURA 25	-	MODELO GERAL DE UM NEURÔNIO ARTIFICIAL.....	65
FIGURA 26	-	FUNÇÕES DE ATIVAÇÃO	67
FIGURA 27	-	REDES DE CAMADAS SIMPLES	69
FIGURA 28	-	REDES MULTICAMADAS	69
FIGURA 29	-	REDES RECORRENTES	70
FIGURA 30	-	EXEMPLOS DE ARQUITETURA DE REDES NEURAIS ARTIFICIAIS	71
FIGURA 31	-	APRENDIZADO SUPERVISIONADO	73
FIGURA 32	-	APRENDIZADO NÃO-SUPERVISIONADO	74
FIGURA 33	-	MODELO GERAL DE ARQUITETURA MLP	75
FIGURA 34	-	ARQUITETURA DA REDE <i>FEEDFORWARD</i>	76

FIGURA 35	-	EXEMPLO DE REDE DE DUAS OU MAIS CAMADAS	77
FIGURA 36	-	REDES DE ELMAN.....	79
FIGURA 37	-	EXEMPLO DA ARQUITETURA DE ELMAN.....	79
FIGURA 38	-	FLUXO DE PROCESSAMENTO DO ALGORITMO RETROPROPAGAÇÃO DO ERRO	80
FIGURA 39	-	LOCAL DE ESTUDO (LITORAL PARANAENSE: CAIOBÁ E MATINHOS).....	89
FIGURA 40	-	FOTO AÉREA VERTICAL DE MATINHOS PARA OS ANOS 1954 E 1997	90
FIGURA 41	-	ESTAÇÃO BASE INSTALADA NO MARCO GEODÉSICO “PEDRA” EM MATINHOS	91
FIGURA 42	-	LOCALIZAÇÃO DA ESTAÇÃO BASE E LIMITES DO MAPEAMENTO.....	92
FIGURA 43	-	LINHAS DE COSTA TEMPORAIS: (a) FOTOGRAMETRIA (b) GPS.....	93
FIGURA 44	-	DIAGRAMA DE BLOCOS PARA O PROCESSO DE TENDÊNCIA DA LINHA DE COSTA.....	94
FIGURA 45	-	LINHAS DE COSTA TEMPORAIS	95
FIGURA 46	-	SEÇÕES TRASNVERSAIS À LINHA DE REFERÊNCIA E DISTÂNCIAS PRÉ-SELECIONADAS ENTRE AS LINHAS TRAÇADAS	96
FIGURA 47	-	PONTOS QUE INTERCEPTAM AS RETAS TRAÇADAS.....	96
FIGURA 48	-	COLETA E ARMAZENAMENTO DOS DADOS EM TABELAS	97
FIGURA 49	-	DIAGRAMAS DE DISPERSÃO, ANO VERSUS DISTÂNCIA EM METROS	97
FIGURA 50	-	LINHA DE COSTA PREDITA PARA O ANO t_{n+1}	98
FIGURA 51	-	LINHA DE REFERÊNCIA ESCOLHIDA E SEÇÕES TRANSVERSAIS	99
FIGURA 52	-	PONTOS DE INTERSECÇÃO ENTRE AS LINHAS DE COSTA TEMPORAIS E SEÇÕES TRANSVERSAIS	100

FIGURA 53	-	NUMERAÇÃO DAS SEÇÕES TRANSVERSAIS (1 à 57).....	102
FIGURA 54	-	“PEDRA” DE MATINHOS.....	108
FIGURA 55	-	GRADE REGULAR DE ALTITUDES ORTOMÉTRICAS E ÁREA DELIMITADA COM ALTITUDE ACIMA DE 4 m.....	108
FIGURA 56	-	COMPARAÇÃO ENTRE ESTIMATIVA ROBUSTA E REGRESSÃO LINEAR MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008.....	127
FIGURA 57	-	COMPARAÇÃO ENTRE ESTIMATIVA ROBUSTA E REDES NEURAIIS MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008.....	127
FIGURA 58	-	COMPARAÇÃO ENTRE REGRESSÃO LINEAR E REDES NEURAIIS MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008.....	128
FIGURA 59	-	TENDÊNCIA DOS MODELO PARA O ANO DE 2055.....	131
FIGURA 60	-	RESTRIÇÃO PARA ALTITUDES ORTOMÉTRICAS ACIMA DE 4 m.....	132
FIGURA 61	-	COMPARAÇÃO COM DIFERENTES ESPAÇAMENTOS DE SEÇÕES TRANSVERSAIS	133
FIGURA 62	-	COMPARAÇÃO DA POSIÇÃO ENTRE DIFERENTES LINHAS DE COSTA TEMPORAIS	134
FIGURA 63	-	TESTES COM OS MODELOS POLINÔMIAIS DE PRIMEIRA E SEGUNDA ORDEM PARA ALGUMAS SEÇÕES TRANSVERSAIS	136
FIGURA 64	-	MODELOS DE TENDÊNCIA PARA LINHA DE COSTA.....	138

LISTA DE QUADROS

QUADRO 1	-	MUNICÍPIOS DO LITORAL DO PARANÁ.....	36
QUADRO 2	-	LOCALIZAÇÃO E EXTENSÃO DOS DIFERENTES TIPOS DE COSTA NO ESTADO DO PARANÁ	39
QUADRO 3	-	COORDENADAS UTM (WGS-84) NOS DISTINTOS ANOS DOS PONTOS DE INTERSEÇÃO.....	100
QUADRO 4	-	DISTÂNCIA DA ORIGEM AO PONTO DE INTERSEÇÃO	101
QUADRO 5	-	DIVISÃO DOS DADOS CONFORME O NÚMERO DE DADOS TEMPORAIS	101
QUADRO 6	-	TESTE 1 COM RNA – MLP USANDO LM.....	109
QUADRO 7	-	TESTE 2 COM RNA – MLP USANDO BAYESIANO COM REGULARIZAÇÕES.....	110
QUADRO 8	-	TESTE 3 COM RNA – ELMAN USANDO QUASE-NEWTON	110
QUADRO 9	-	RESUMO DOS TESTES EFETUADOS	115
QUADRO 10	-	TESTE PARA A MATRIZ DE PESO 1.....	116
QUADRO 11	-	AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 1 EM RELAÇÃO À LINHA DE COSTA GPS2008	117
QUADRO 12	-	TESTE PARA A MATRIZ DE PESO 2.....	117
QUADRO 13	-	AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 2 EM RELAÇÃO À LINHA DE COSTA GPS2008	118
QUADRO 14	-	TESTE PARA A MATRIZ DE PESO 3.....	118
QUADRO 15	-	AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 3 EM RELAÇÃO À LINHA DE COSTA GPS2008	119
QUADRO 16	-	RESULTADOS DO TESTE 1 COM RNA DO TIPO MLP USANDO LM	121
QUADRO 17	-	AVALIAÇÃO ESTATÍSTICA PARA O TESTE 1.....	121

QUADRO 18	-	RESULTADOS DO TESTE 2 COM RNA DO TIPO MLP USANDO O MÉTODO BAYESIANO COM REGULARIZAÇÃO	122
QUADRO 19	-	AVALIAÇÃO ESTATÍSTICA PARA O TESTE COM A RNA 2.....	122
QUADRO 20	-	TESTE 3 COM RNA DO TIPO ELMAN USANDO QUASE-NEWTON	123
QUADRO 21	-	AVALIAÇÃO ESTATÍSTICA PARA O TESTE 3	123
QUADRO 22	-	RESÍDUOS OBTIDOS PARA 2008	125
QUADRO 23	-	AVALIAÇÕES ESTATÍSTICAS PARA A TENDÊNCIA DE 2008.....	126
QUADRO 24	-	POSIÇÕES E DESVIOS DE LINHA DE COSTA PARA 2055	129
QUADRO 25	-	AVALIAÇÕES ESTATÍSTICAS ENTRE OS MODELOS DE TENDÊNCIA PARA O ANO DE 2055	130
QUADRO 26	-	SEÇÕES SELECIONADAS PARA O TESTE DE MUDANÇA DE MODELO MATEMÁTICO	135
QUADRO 27	-	RESULTADOS PARA DIFERENTES MODELOS MATEMÁTICOS.....	137

LISTA DE SIGLAS

CGIS	-	<i>Coastal Geographic Information System</i>
DHN	-	Diretoria de Hidrografia e Navegação
DIAMAT	-	Determinação do Impacto Ambiental Decorrente da Ação Antrópica na Linha Costeira da Região de Matinhos.
ER	-	Estimativa Robusta
GIS	-	<i>Geographic Information System</i>
GLONASS	-	<i>Global Navigation Satellite System</i>
GNSS	-	<i>Global Navigation Satellite Systems</i>
GPS	-	<i>Global Positioning System</i>
IGDC	-	<i>International Geographic Data Committee</i>
INPE	-	Instituto Nacional de Pesquisas Espaciais
LAGE	-	Laboratório de Geodésia Espacial
LIDAR	-	<i>Light Detection and Ranging</i>
MDL	-	<i>Minimum Description Length</i>
MDT	-	Modelo Digital do Terreno
MLP	-	<i>Multilayer Perceptron</i>
MMA	-	Ministério do Meio Ambiente
PNGC	-	Plano Nacional de Gerenciamento Costeiro
RL	-	Regressão Linear
RNA	-	Redes Neurais Artificiais
RMSE	-	<i>Root Mean Square Error</i>
RMS	-	<i>Root Mean Square</i>
RTK	-	<i>Real Time Kinematic</i>
SAD	-	<i>South American Datum</i>
SIG	-	Sistema de Informação Geográfica
SSE	-	<i>Sum of Square Error</i>
UTM	-	<i>Universal Transverse of Mercator</i>
WGS	-	<i>World Geodetic System</i>

SUMÁRIO

1 INTRODUÇÃO	19
1.1 OBJETIVO GERAL	25
1.2 OBJETIVOS ESPECÍFICOS	25
1.3 JUSTIFICATIVA	26
1.4 CONTRIBUIÇÕES DA TESE	27
1.5 ESTRUTURA DO TRABALHO	28
2 REVISÃO DE LITERATURA	29
2.1 LINHA DE COSTA E EROSÃO COSTEIRA	29
2.2 MUDANÇAS NATURAIS DA LINHA DE COSTA	33
2.3 LOCALIZAÇÃO E CARACTERÍSTICAS FÍSICAS DO LITORAL PARANAENSE	35
2.3.1 Histórico da ocupação do litoral para o balneário de Matinhos	40
2.4 MÉTODOS DE EXTRAÇÃO DA LINHA DE COSTA	46
2.4.1 Aerofotogrametria	46
2.4.2 Sensoriamento remoto por imagens de satélites	47
2.4.3 LIDAR (<i>Light Detection and Ranging</i>)	49
2.4.5 NAVSTAR-GPS	50
2.5 CONVERSÃO DOS DADOS TEMPORAIS PARA O MESMO SISTEMA DE REFERÊNCIA GEODÉSICO	52
2.6 CONSTRUINDO MODELOS EMPÍRICOS	53
2.6.1 Regressão linear simples	53
2.6.2 Estimativa robusta	58
2.6.3 Redes neurais artificiais	63
2.6.3.1 Arquitetura	68
2.6.3.2 Aprendizado	72
2.6.3.3 Perceptron multicamadas	75
2.6.3.4 Modelo neural	75
2.6.3.5 Rede parcialmente recorrente de Elman	78
2.6.3.6 O algoritmo de aprendizagem retropropagação do erro	80
2.6.3.7 Método Levenberg-Marquardt (LM)	83
2.6.3.8 Método Bayesiano com regularização	85
2.6.3.9 Método quase-Newton	85
3 MATERIAL E MÉTODOS	87
3.1 RECURSOS UTILIZADOS, COOPERAÇÃO E SUPORTE	87
3.2 MATERIAL	88
3.3.1 Levantamento da linha de costa	91
3.3.2 Linhas de costa temporais obtidas por monorestituição e GPS	93
3.4 MÉTODOS DE TENDÊNCIA PARA LINHA DE COSTA	94
3.4.1 Experimento prático para aplicação dos modelos de tendência	99
3.4.2 Critérios de Avaliação	111
4 RESULTADOS E DISCUSSÃO	115
4.1 RESULTADOS PARA TENDÊNCIA DA LINHA DE COSTA PARA O ANO DE 2008	115

4.1.1 Resultados para os testes utilizando estimativa robusta e regressão linear	115
4.1.2 Resultados dos testes utilizando Redes Neurais Artificiais	120
4.1.3 Análise conjunta dos três modelos de tendência, selecionando o caso de melhor desempenho para cada um deles	125
4.2 OS RESULTADOS DE TENDÊNCIA POSICIONAL DA LINHA DE COSTA PARA O ANO 2055	129
4.3 RESTRIÇÃO PARA A LOCALIZAÇÃO DA “PEDRA” DE MATINHOS	131
4.4 TESTE COM DIFERENTES DISTÂNCIAS ENTRE AS SEÇÕES TRANSVERSAIS	132
4.5 FORMAÇÃO DO BANCO DE DADOS TEMPORAIS COM AS INFORMAÇÕES GEODÉSICAS	133
4.6 O MODELO MATEMÁTICO PARA LINHA DE COSTA	135
5 CONCLUSÕES E RECOMENDAÇÕES	139
5.1 CONCLUSÕES	139
5.2 RECOMENDAÇÕES	143
REFERÊNCIAS	145

1 INTRODUÇÃO

Muitas praias são conhecidas por possuírem ocorrência de erosão costeira. Estima-se que 70% das zonas costeiras com praias arenosas do mundo estão sofrendo processos erosivos, 10% estão em progradação e 20% restantes encontram-se em relativa estabilidade (BIRD, 1996). No Brasil, a ocupação desordenada agrava essa situação e centenas de praias estão sob efeitos severos de erosão (detalhes em, SOUZA, 2009). A zona litorânea também é importante e conhecida por ser uma área com forte potencial turístico que amplia a economia local. Uma forma de realizar eficientemente o gerenciamento é investir no monitoramento geodésico da linha de costa, que desempenha um papel essencial para o planejamento territorial.

A linha de costa pode ser definida como o limite entre o continente e a porção adjacente ao mar onde não há efetiva ação marinha no alcance máximo das ondas, concretizando-se pela presença de falésias, no limite entre a vegetação e a praia, ou nos costões rochosos, ou por qualquer outra feição que marque o início da área continental (SUGUIO, 1992). A posição da linha de costa é instável, variando de acordo com o tempo, sofrendo os efeitos de avanço e recuo na sua posição. As mudanças a longo-prazo são relatadas como as mudanças causadas pelo aumento do nível médio dos mares, com o transporte de sedimentos, ondas, controles geológicos, que causam o avanço e recuo do mar em um período centenário ou milenar. As mudanças a curto-prazo, por sua vez, são aquelas que ocorrem em um período de 80 anos ou menos e estão relacionadas com a variação diária, mensal e sazonal da maré, correntes, ondas, clima, fatores antrópicos e eventos episódicos considerados como mudanças muito rápidas. Estas podem ocorrer como resultado de uma tempestade tropical ou furacões, causando, por exemplo, mudanças de 30 metros na posição da linha de costa em apenas um dia (GIBEAUT *et al.*, 2001). A complexidade na definição da linha de costa, seu mapeamento e utilização são discutidos, por exemplo, em Li *et al.* (2001).

Monitorar a estabilidade costeira é vital para gestão do meio ambiente e faz parte do conjunto de tarefas e atividades que contribuem com o gerenciamento costeiro. Mediante o monitoramento contínuo, profissionais responsáveis por tomar decisões são

informados sobre os agentes e variáveis que envolvem o comportamento da linha de costa. Monitorar é essencial para reunir e organizar com consistência o conjunto de dados posicionais que represente a evolução da posição da linha de costa em uma determinada área de estudo. O *Metropolitan Borough of Sefton* (2002) apresentou uma lista dos benefícios em obter informações a respeito da evolução da linha de costa: providenciar dados de entrada para verificar a posição da linha de costa e seu planejamento; planejar a manutenção de defesas costeiras; demarcar locais de risco; determinar um apropriado critério de ocupação; gerar um plano de ação a respeito da biodiversidade; programar normas para habitação e aprendizado para gestão de áreas costeiras. A informação sobre linha de costa também é utilizada para dar suporte, por exemplo, ao monitoramento da microbiologia e ondas marinhas (ver, detalhes em exemplo, SCHIFF e WEISBERG, 2001).

No Brasil, o projeto Orla conduzido pelo MMA (Ministério do Meio Ambiente) no que diz respeito aos sistemas de informações do gerenciamento costeiro e marinho cita e propõe um sistema que integra e disponibiliza informações do PNGC (Plano Nacional de Gerenciamento Costeiro) com dados de várias fontes entre elas encontram-se: banco de dados, sistemas de informações geográficas e produtos de sensoriamento remoto. Este projeto apresenta um dispositivo para sistema de monitoramento ambiental com a proposição de uma estrutura operacional contínua de coleta de dados. Busca-se desta forma o acompanhamento da dinâmica de uso e ocupação da zona costeira direcionados para metas de qualidade sócio-ambiental que levam em consideração indicadores de qualidade para avaliar a dinâmica e os impactos das atividades sócio-econômicas, relacionadas ao setor industrial, turístico, portuário e pesqueiro (SOUZA, 2009).

O monitoramento da linha de costa se beneficia do posicionamento global (GNSS - *Global Navigation Satellite Systems*) através de levantamentos geodésicos usando o sistema americano GPS (*Global Positioning System*); o sistema russo GLONASS (*GLObal NAvigation Satellite System*); e em breve o sistema europeu Galileo e o sistema chinês *Beidou* (ou *Compass*).

Outras técnicas que são utilizadas para o mapeamento da linha de costa são as relacionadas ao Sensoriamento Remoto, e entre as mais utilizadas encontram-se:

imagens de satélites, fotografias aéreas (aerofotogrametria) e dados (levantamentos) LIDAR (*Light Detection and Ranging*). Esses métodos são elaborados e discutidos, por exemplo, por Gorman *et al.* (1998). White e El Asmar (1999) elaboraram uma ilustração onde se utilizou imagens temáticas de satélites para monitorar mudanças de posições nas linhas de costa no Delta do Rio Nilo (Egito). Para otimizar esse monitoramento, ferramentas com o uso do SIG (Sistemas de Informação Geográfica) são utilizadas para analisar mudanças naturais de um determinado fenômeno de acordo com a evolução no tempo, utilizando modelos espaço-temporais que são referidos como *Coastal Geographic Information System* (CGIS). Como exemplo, um CGIS foi utilizado por Li *et al.* (2001) para monitorar a linha de costa da Malásia.

As áreas onde o monitoramento da linha de costa é essencial vêm sendo estudadas. Simular a tendência da sua posição é igualmente vital para fornecer informações ao gerenciamento costeiro e aos programas de impacto ambiental (HECKY *et al.*, 1984). Também é útil para dar suporte à construção de proteção costeira conforme uma esperada data limite para a vida útil dessa obra, normalmente planejada para 30 ou 60 anos. Crowell *et al.* (1997) relatam que, para determinar uma proteção costeira adequada é necessário uma predição posicional a longo-prazo da linha de costa baseada em tendências de dados históricos que forneçam o mapeamento desta feição.

Fenster *et al.* (1993) desenvolveram um modelo preditivo para detectar mudanças a curto-prazo (utilizando um banco de dados contendo informações de mudanças a longo-prazo) e identificar modelos lineares ou de ordem superior que melhor se ajustem em um conjunto de dados, de acordo com o critério de descrição do comprimento mínimo (MDL) (*Minimum Description Length Criterion*). Neste método, apenas os modelos lineares são extrapolados.

As predições formuladas com polinômios de ordem maior podem obter resultados superiores que o da regressão linear simples. Porém, eles podem ser extremamente não-acurados para simulações futuras (CROWELL *et al.*, 1997). Douglas *et al.* (1998) salientaram a necessidade de incorporar em tendências erosivas de longo-prazo dados de tempestades, incluindo seus impactos na posição de linha de costa e recuperação de praias em modelos preditivos.

Explorando a relação entre mudança de linha de costa e mudanças no nível médio dos mares (por exemplo, utilizando séries temporais amostradas de valores do nível médio do mar como dados para mudança de linha de costa), Douglas *et al.* (1998) desenvolveram uma metodologia para testar modelagens preditivas através do método do ponto final (*end point method*) e regressão linear. Foram simuladas algumas posições conhecidas de linha de costa e ficou estabelecido que os melhores resultados encontrados provinham do modelo que aplicava o método de regressão linear.

Douglas e Crowell (2000) apontam que é viável a elaboração de modelos preditivos com precisão de dezenas de metros, pois se deve considerar a variabilidade inerente da posição da linha de costa.

Crowell *et al.* (1997) e Douglas *et al.* (1998) ressaltam que, freqüentemente, os dados utilizados em modelos de predição são pobremente amostrados em banco de dados históricos de linha de costa e destacam que um conjunto temporal apresentando poucas informações posicionais, muitas vezes, não é ideal para a aplicação em modelos preditivos.

Recuperar e obter informações históricas organizadas sobre mapeamentos e levantamentos geodésicos é uma tarefa difícil. Muitos documentos cartográficos, após o término do seu projeto, perdem-se por simples descuido, e esse fato infelizmente acontece com freqüência no Brasil. Desde 1996, o Laboratório de Geodésia Espacial (LAGE) na Universidade Federal do Paraná (UFPR) realiza projetos de pesquisa com campanhas e levantamentos geodésicos na costa do Estado do Paraná. Os dados são compostos de documentos cartográficos digitais com relatórios mostrando o pós-processamento e precisões alcançadas em cada levantamento de campo.

Com o propósito de estudar as variações de linha de costa no Paraná e desenvolver um modelo para verificar sua tendência a curto-prazo foi necessário buscar informações cartográficas históricas sobre o tema. Os materiais de projetos antigos foram encontrados, e esses dados se referem aos anos 1954, 1963, 1980, 1991 e 1997 utilizados para extração de linha de costa em uma zona costeira com extensão de 6 km no Município de Matinhos, no Estado do Paraná.

Alguns problemas para extrair informações sobre esse material estão relacionados com a qualidade cartográfica nas fotos aéreas verticais mais antigas (1954

e 1963) e problemas geométricos devido à dificuldade de encontrar pontos de controle nas mesmas. O cenário das fotografias da costa no passado era composto apenas por vegetação e oceano, contendo poucas feições identificáveis para serem utilizadas como controle fotogramétrico. Porém, destaca-se que a qualidade métrica obtida por fotografias aéreas é importante e, muitas vezes, são os únicos dados disponíveis para formar um conjunto de informações temporais em zonas costeiras.

A extração da linha de costa utilizando esse material fotogramétrico foi realizada pela técnica de monorestituição digital (MITISHITA, 1997). Essa técnica requer informações altimétricas; depende da qualidade das fotos; da distribuição e número de pontos de controle e da fotointerpretação do operador para extração da linha de costa.

Usando os dados posicionais temporais provenientes da fotogrametria e dados obtidos por receptores GPS para os anos de 2001, 2002, 2005 e 2008, nesta tese discute-se:

É possível elaborar uma modelagem de tendência da posição da linha de costa a curto-prazo utilizando diferentes fontes de dados geodésicos temporais? Quais as aplicabilidades e diferenças encontradas comparando diferentes modelos de tendência para a área de estudo?

Para dar suporte à solução destas questões é elaborada uma metodologia utilizando três modelos de tendência para linha de costa quais sejam: regressão linear, estimativa robusta e redes neurais artificiais.

Os modelos foram testados sobre o conjunto de dados obtidos para prever a posição da linha de costa para o ano de 2008. O resultado desta tendência é comparado com a posição da linha de costa obtida por levantamento relativo cinemático utilizando receptores GPS para o mesmo ano.

O modelo de regressão linear apresenta solução desejável quando os critérios de linearidade e distribuição normal são respeitados. Em alguns casos, a fonte de dados históricos, como é o caso da fotogrametria, são de difícil interpretação para extração da posição de linha de costa. Nesses casos, os critérios de regressões lineares podem ser violados. As incertezas na extração de linha de costa têm que ser tratadas de forma apropriada quando utilizadas em modelos de predição (ver, por exemplo, Addo *et al.* 2008).

Os modelos de estimativa robusta são propostos para lidar em casos como os mencionados anteriormente (ver, por exemplo Huber (1964), Huber (1981), Hampel *et al.* (1986) e Aduol (1994). Nesta tese é demonstrada o comportamento dos modelos de estimativa robusta para o caso de predição de linha de costa. Esse modelo foi aplicado com sucesso por Awange e Aduol (1999) em uma simulação para solucionar o cálculo de uma poligonal geodésica quando observações de distâncias e ângulos são propositalmente contaminados com erros grosseiros.

As redes neurais artificiais, com ampla aplicação em vários ramos da ciência, foram testadas como modelo preditivo de linha de costa utilizando a arquitetura da rede neural *perceptron* multicamadas (MLP, *Multilayer Perceptron*) e a rede neural parcialmente recorrente de Elman.

Os resultados indicam a aplicabilidade dos modelos para simular a tendência na posição da linha de costa. Detalhes da elaboração dos modelos, testes realizados e resultados experimentais com dados do município litorâneo de Matinhos, no Estado do Paraná, são apresentados no decorrer desta tese.

1.1 OBJETIVO GERAL

O objetivo geral desta pesquisa é a elaboração de uma modelagem para verificar a tendência de variação posicional da linha de costa a curto-prazo, baseada em dados geodésicos temporais, utilizando e investigando o comportamento dos modelos de regressão linear, estimativa robusta e redes neurais artificiais com os dados obtidos para região de estudo que compreende parte do Município de Matinhos, no Estado do Paraná.

1.2 OBJETIVOS ESPECÍFICOS

Para atingir o objetivo geral, os seguintes objetivos específicos são realizados:

- Resgatar de projetos de pesquisa os dados históricos de posição espacial da linha de costa referente à área de estudo.
- Efetuar novos mapeamentos por meio de levantamentos geodésicos, possibilitando o monitoramento contínuo da linha de costa.
- Organizar os dados espaço-temporais em um SIG costeiro contendo dados provenientes de extração da linha de costa, conforme os métodos de mapeamentos históricos realizados, quais sejam: sensoriamento remoto e geodésia espacial.
- Elaborar uma metodologia com diferentes modelos preditivos.
- Predizer a tendência de variação posicional da linha de costa com os modelos elaborados.

- Comparar os resultados gerados entre os modelos: regressão linear, estimativa robusta e redes neurais artificiais.
- Verificar a qualidade da predição comparando os dados produzidos pelo levantamento geodésico da linha de costa para o ano de 2008, com os preditos para este mesmo ano.

1.3 JUSTIFICATIVA

As ciências geodésicas têm um papel fundamental para mapear ambientes costeiros. Através de mapeamentos históricos de linha de costa é possível verificar a dinâmica de um local em estudo.

Estudar modelagens baseando-se em dados geodésicos temporais com a possibilidade de prever a posição de linha de costa é uma informação importante e auxilia de maneira significativa na gestão e tomada de decisões que envolvem a ocupação costeira.

O fenômeno de erosão costeira é um fato à nível mundial. Os modelos preditivos para ambientes costeiros no Brasil representam uma frente de trabalho pouco explorada.

Internacionalmente, o modelo preditivo mais aceito para verificar a tendência de variação posicional da linha de costa é o de regressão linear. Porém, para o estudo de ambientes costeiros é necessário fazer uso de dados e informações referentes à posição de linha de costa no passado, por exemplo, de 50, 60 anos atrás ou mais e estes dados dependem da qualidade da sua extração e interpretação. Na prática, quando dados antigos são agregados ao conjunto de observações temporais, não se tomando os devidos cuidados em seu tratamento cartográfico, estes podem contribuir para representar predições fora da realidade.

Analisar a aplicabilidade de diferentes modelos preditivos, tanto nacionalmente, como internacionalmente é uma linha de pesquisa importante, o que torna esta tese um esforço inicial para este tipo de questionamento.

Destaca-se que a hipótese de descartar dados antigos não é atraente para o ambiente costeiro, pois estes são importantes para o resgate de informações. Busca-se trabalhar com todos os dados históricos da posição de linha de costa disponíveis, porém com modelos capazes de ponderar os dados antigos de forma eficiente.

Justifica-se, assim, a busca por novos modelos de predição, utilizando métodos iterativos e eficientes, capazes de serem aplicados em modelagens preditivas da tendência de linha de costa, como são os casos da estimativa robusta e das redes neurais artificiais.

1.4 CONTRIBUIÇÕES DA TESE

Novos levantamentos geodésicos de linha de costa na área de estudo foram realizados a partir de um projeto final de graduação em Engenharia Cartográfica (MAIA e MAZUR, 2008), este co-orientado pelo autor desta tese.

A partir de reuniões no início deste trabalho em 2006 foi apresentada uma idéia para uma dissertação de mestrado que teve como propósito estudar as técnicas de levantamentos geodésicos utilizando receptores GPS para mapeamentos costeiros (TANAJURA, 2008).

Esforços no sentido de recuperar documentos cartográficos relacionados à área de estudo e organizar um SIG costeiro foram efetuados.

Foi desenvolvida a elaboração de uma metodologia aplicando três modelagens de tendência de variação de linha de costa utilizando os seguintes métodos: regressão linear, estimativa robusta e redes neurais artificiais.

Com os resultados referentes à área litorânea de Matinhos foi possível verificar, como estudo de caso, a aplicabilidade dos modelos de tendência de linha de costa.

Destaca-se o estabelecimento da parceria com o Instituto de Geodésia da Universidade de Karlsruhe na Alemanha que demonstrou interesse nesse trabalho e forneceu subsídios para dar continuidade à pesquisa no período do doutorado sanduíche realizado dentro do projeto PROBRAL intitulado “Densificação do SIRGAS no Brasil com o posicionamento GPS de alta precisão: modelagem de erros e integração da componente vertical”.

1.5 ESTRUTURA DO TRABALHO

A estrutura da tese consiste em cinco capítulos. No primeiro capítulo foi apresentada a introdução, os objetivos a serem atingidos, a justificativa e as contribuições da tese. No capítulo 2 encontra-se uma revisão de literatura sobre linha de costa e erosão costeira; mudanças naturais de linha de costa; localização e características físicas do litoral paranaense; métodos de extração da linha de costa e uma revisão sobre os modelos preditivos aplicados. No capítulo 3 relatam-se os materiais e métodos empregados como partes integrantes da metodologia. Os resultados e discussões estão apresentados e descritos no capítulo 4. O capítulo 5 apresenta as conclusões finais.

2 REVISÃO DE LITERATURA

2.1 LINHA DE COSTA E EROSÃO COSTEIRA

O desafio inicial para detecção, monitoramento e predição da linha de costa é desenvolver uma técnica eficaz capaz de identificar e mapear a feição denominada como “linha de costa” de acordo com os dados fontes (cartográficos) disponíveis (BOAK e TURNER, 2005).

O conceito de linha de costa é simplesmente o *limite entre o continente e o mar*. É necessário, de acordo com a aplicação, definir o que seria exatamente esse limite de separação entre estas duas porções: mar e continente.

A FIGURA 1 é uma fotografia da zona costeira de Matinhos (2007) pertencente ao local de estudo. Nela estão indicadas duas feições costeiras nomeadas como: linha de água instantânea (A) e falésia ou escarpa erosiva (B).




FIGURA 1 - LINHA DE COSTA E LINHA DE ÁGUA INSTANTÂNEA

Analisando a linha de água instantânea verifica-se que ela é dependente de um processo dinâmico chamado de maré astronômica, que depende da posição da Lua e do Sol em relação à Terra. Os seus picos máximos ocorrem na Lua cheia ou na Lua nova, e são chamados de preamar e baixa-mar de sizígia. O Centro de Estudos do Mar (CEM) fornece em seu site, por exemplo, a previsão horária de marés. A FIGURA 2 apresenta essa previsão para o dia 13/Set/2008.




FIGURA 2 - PREVISÃO DE MARÉS *ONLINE*: GUARATUBA - 13/09/2008
 FONTE: <http://www.cem.ufpr.br/mares.htm>

Na FIGURA 2 é possível verificar o horário e os respectivos picos de preamar e baixa-mar. A FIGURA 3 mostra a movimentação da maré, tomadas na área de estudo em Matinhos no dia 13/09/2008.



FIGURA 3 – PREAMAR E BAIXAMAR NO MUNICÍPIO DE MATINHOS, FOTOS TIRADAS EM 13/09/2008.
 FONTE: MAIA e MAZUR (2008)

Analisando este exemplo ilustrativo e simplificado do efeito de maré verifica-se que o ambiente costeiro remete a um sistema dinâmico. Neste momento, a questão que fica em aberto e está em análise é identificar um elemento possível de ser mapeado e que seja utilizada de forma consistente como linha de costa.

Um documento cartográfico é algo estático, ou seja, um mapa representa a posição de determinadas feições para aquele instante de tempo. Sendo assim, a linha de água instantânea, por exemplo, não seria um elemento ideal para ser utilizado como indicativo da linha de costa.

O LAGE (Laboratório de Geodésia Espacial da UFPR) vem empregando a seguinte definição para linha de costa: *é o limite entre o continente e a porção adjacente ao mar onde não há efetiva ação marinha no alcance máximo das ondas, concretizando-se pela presença de falésias, no limite entre a vegetação e a praia, ou nos costões rochosos, ou por qualquer outra feição que marque o início da área continental* (SUGUIO, 1992).

Para esclarecer esta definição faz-se o uso da FIGURA 4, que mostra exemplos de dois cenários encontrados na área de estudo e a posição da linha de costa utilizada traçada na fotografia. No exemplo do trecho (a) a linha de costa é o *limite entre a vegetação e a praia*; no segundo caso (b) a linha de costa é o limite do continente caracterizado pela infra-estrutura urbana considerada como *feição que demarca o início da área continental no alcance máximo das ondas*.

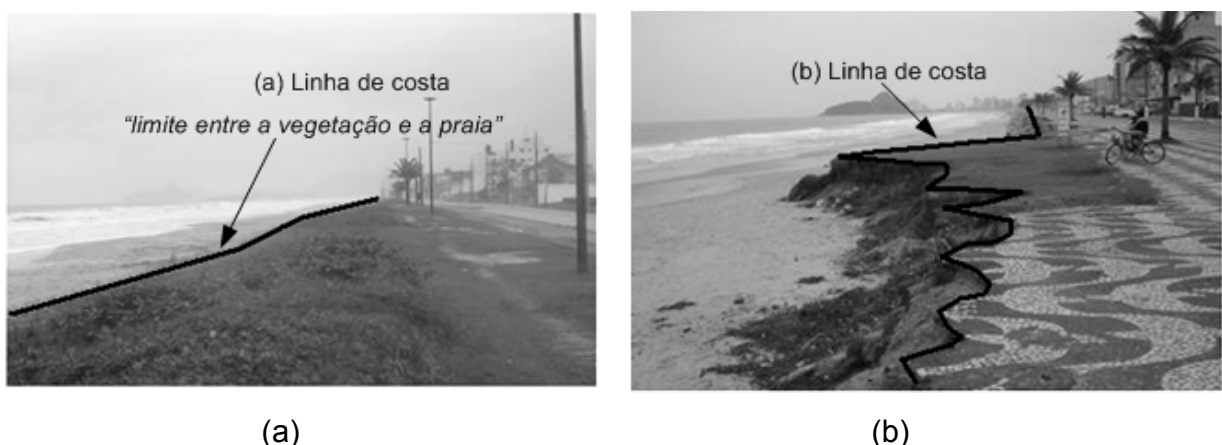


FIGURA 4 – DIFERENTES CONFIGURAÇÕES DA LINHA DE COSTA NA ÁREA DE ESTUDO (A) LIMITE ENTRE A VEGETAÇÃO E A PRAIA (B) LIMITE ENTRE A PRAIA E O CONTINENTE (CALÇADA)

Alguns termos são utilizados para denominar o processo de erosão marinha, entre eles a erosão costeira, erosão da praia ou praiial, erosão da falésia marinha, recuo da praia, erosão da linha de costa, recuo da linha de costa, entre outros (SOARES, 1995).

De acordo com Pilkey e Thielér (1992) é difícil definir erosão no ambiente costeiro, pois os termos recuo e progradação referem-se a mudanças na posição da linha de costa e erosão e acreção referem-se a mudanças volumétricas que ocorrem nas praias. Para esses autores, o termo que melhor expressa uma erosão costeira é o recuo da linha de costa (SOARES, 1995).

A erosão marinha é definida em Soares (1995) como um processo natural ou induzido pelo homem, regido pela ação de ondas, marés, correntes, ventos ou variações do nível do mar, que resulta no recuo da linha de costa, através da remoção do material sedimentar das praias ou de qualquer outro tipo de material exposto nas falésias.

Normalmente o processo é resultado da ação física dos agentes (vento, onda, maré, deriva litorânea) que atuam sobre a linha de costa, mas fenômenos como os de dissolução, através do intemperismo químico, podem ser auxiliares no recuo. O processo oposto, o avanço da linha de costa, pode ser chamado de progradação (SOARES, 1995).

Existe ainda a distinção entre erosão e problema erosivo. O termo erosão constitui um importante processo na evolução das formas de relevo holocênicas, como estuários, lagunas, esporões, ilhas, barreiras, entre outras que têm, pelo menos em parte, sua origem relacionada com erosão (SOARES, 1995).

Um problema erosivo existe somente quando o processo atua em áreas ocupadas pelo homem, causando danos aos investimentos por ele efetuados na linha de costa. Sendo assim, o problema de erosão marinha é um conceito entendido desta forma pelo homem, uma vez que há áreas ocupadas no litoral que estão submetidas

aos fenômenos fluviais, oceanográficos, meteorológicos, atmosféricos e astronômicos que promovem e disparam os processos erosivos (PIKEY, 1991 e SOARES, 1995).

2.2 MUDANÇAS NATURAIS DA LINHA DE COSTA

As praias têm como característica natural mudanças em seu formato e variações na posição da linha de costa. Essas mudanças são causadas por forças que movem os sedimentos, entre elas encontram-se: ações referentes ao vento, correntes marinhas, ondas, e transporte de areia. Mudanças do nível relativo do mar também implicam em mudanças no movimento da linha de costa (GIBEAUT *et al.*, 2001). Além das mudanças naturais a presença antrópica e as atividades econômicas podem trazer consequências causando impactos em um ambiente costeiro.

Para tentar entender e prever uma taxa de mudança nas linhas de costa é necessário fazer distinção entre mudança a longo-prazo (*long-term change*) e mudança a curto-prazo (*short-term change*) (GIBEAUT *et al.*, 2001).

As mudanças a longo-prazo podem estar relacionadas com mudanças no nível médio dos mares, transporte de sedimentos, energia de ondas, controles geológicos (contemporâneos e antecedentes) e fatores antropogênicos sobre a costa causando movimentos em sua posição sobre um período centenário ou milenário. As mudanças consideradas como curto-prazo, por outro lado, podem ocorrer em escalas de tempo de 80 anos ou menores e estão relacionadas com a movimentação diária, mensal ou sazonal das variações das marés, correntes, ondas, clima e eventos episódicos (ver por exemplo, DEMAREST e LEATHERMAN, 1985; GALGANO *et al.* 1998; GALGANO e DOUGLAS, 2000).

As mudanças rápidas (episódicas) em linhas de costa podem ocorrer como

resultado de uma tempestade tropical ou um furacão, e pode mover a linha de costa, por exemplo, em 30 m em apenas um dia (GIBEAUT *et al.*, 2001).

Fenster *et al.* (1993) descrevem o movimento da linha de costa como um fenômeno complexo e as dificuldades envolvidas em distinguir longo-prazo de mudança (sinal) de curto-prazo de mudança (ruído). Eles destacam que para análises de longo-prazo os efeitos de tempestades devem ser considerados e utilizados como importantes dados em uma distribuição temporal (ver também em FENSTER *et al.*, 2000).

A FIGURA 5 apresenta uma linha indicando a predição da posição de linha de costa a curto-prazo para o ano de 2060, utilizando o modelo de regressão linear simples. Esta área de costa localiza-se no Texas, Estados Unidos da América. É possível verificar nessa simulação, que parte das construções podem desaparecer caso ocorra o recuo da linha de costa predito pelo modelo utilizado.



FIGURA 5 - EXEMPLO DE LINHA DE COSTA PREDITA PARA 2060 NO TEXAS, ESTADOS UNIDOS DA AMÉRICA
FONTE: GIBEAUT (2007b)

As tempestades tropicais, entre outros eventos denominados como “ressacas”, podem causar movimentos da linha de costa de muitos metros em apenas um dia. A FIGURA 6 apresenta fotos após a ressaca do mar ocorrida em maio de 2001 em

Matinhos, que ocasionou o recuo da linha de costa, danificando construções próximas ao mar.



FIGURA 6- RESSACA DE MATINHOS EM MAIO DE 2001
FONTE: KRUEGER *et al.* (2002)

2.3 LOCALIZAÇÃO E CARACTERÍSTICAS FÍSICAS DO LITORAL PARANAENSE

Na parte experimental dos modelos preditivos desta tese utilizou-se como área de estudo o Balneário de Matinhos localizado no estado do Paraná, onde as praias da costa do litoral paranaense apresentam uma extensão de aproximadamente 105 km, representando o segundo menor litoral estadual da costa brasileira. A seguir, nesta seção, algumas características físicas do litoral paranaense e posteriormente um breve histórico da área de estudo específica são apresentados.

O litoral do Paraná é dividido em sete municípios: Guaraqueçaba, Antonina, Morretes, Paranaguá, Pontal do Paraná, Matinhos e Guaratuba. Antonina e Morretes estão localizados no fundo da Baía de Paranaguá e não alcançam o mar aberto. Matinhos é o único que tem costa exclusivamente para mar aberto. Em área, Matinhos é o menor com 115,5 km² (2% do total litorâneo paranaense) e o maior é Guaraqueçaba com 2.159,3 km². O QUADRO 1 apresenta os seguintes dados: ano de

instalação, distância até a capital, área, população e densidade demográfica para o ano 2000, conforme o município do litoral paranaense em questão.

Município	Ano de instalação	Distância até a capital	Área (km ²)	População (2000)	Densidade demográfica (2000)
Paranaguá	1648	84	665,8	127.339	191
Guaratuba	1947	111	1326,8	27.257	21
Antonina	1857	63	968,8	19.174	20
Morretes	1841	65	686,5	15.275	22
Guaraqueçaba	1947	158	2.159,30	8.288	4
Matinhos	1968	103	111,5	24.184	217
Pontal do Paraná	1997	112	216,2	14.323	66
Total	-	-	6.134,40	235.840	38

QUADRO 1- MUNICÍPIOS DO LITORAL DO PARANÁ
FONTE: IBGE (2001)

Segundo o IBGE (2006) a população total do litoral paranaense em 2000 (QUADRO 1), era de 235.840 habitantes; em 2006, de 280.833 habitantes e em 2010, atingirá 311.216 habitantes, incrementando seu peso na população total do estado de 2,5% em 2000, 2,7% em 2006 e 2,9% em 2010.

O litoral paranaense se localiza entre os paralelos 25°S e 26°S de latitude e os meridianos 48°W e 49°W de longitude. Tem uma superfície de 6.061,2 km² que representa 3% da superfície do Paraná. A FIGURA 7 apresenta as regiões geográficas naturais do estado do Paraná, segundo Maack (1968).




FIGURA 7 - LOCALIZAÇÃO DO LITORAL PARANAENSE E DEMAIS REGIÕES NATURAIS DO PARANÁ
FONTE: ANGULO (2004)

O Paraná é um estado de planaltos, que perfazem em torno de 95% do seu território, sendo as outras duas unidades de paisagem a Serra do Mar e o litoral, com apenas 5%. Nelas ocorrem morros e serras de até 1600m de altitude, remanescentes de antigos planaltos, planícies e leques aluviais, planícies costeiras, grandes ilhas costeiras e complexos estuarinos (FIGURA 8) (PIERRI *et al.*, 2006).

No litoral paranaense há uma grande diversidade física e biológica e essas características naturais influenciaram a sua ocupação de acordo com o seu uso. Sendo assim, é possível identificar tendências e caracterizar conflitos através de análises entre relações que envolvem a ocupação costeira, sua base natural e seu uso (PIERRI *et al.*, 2006).

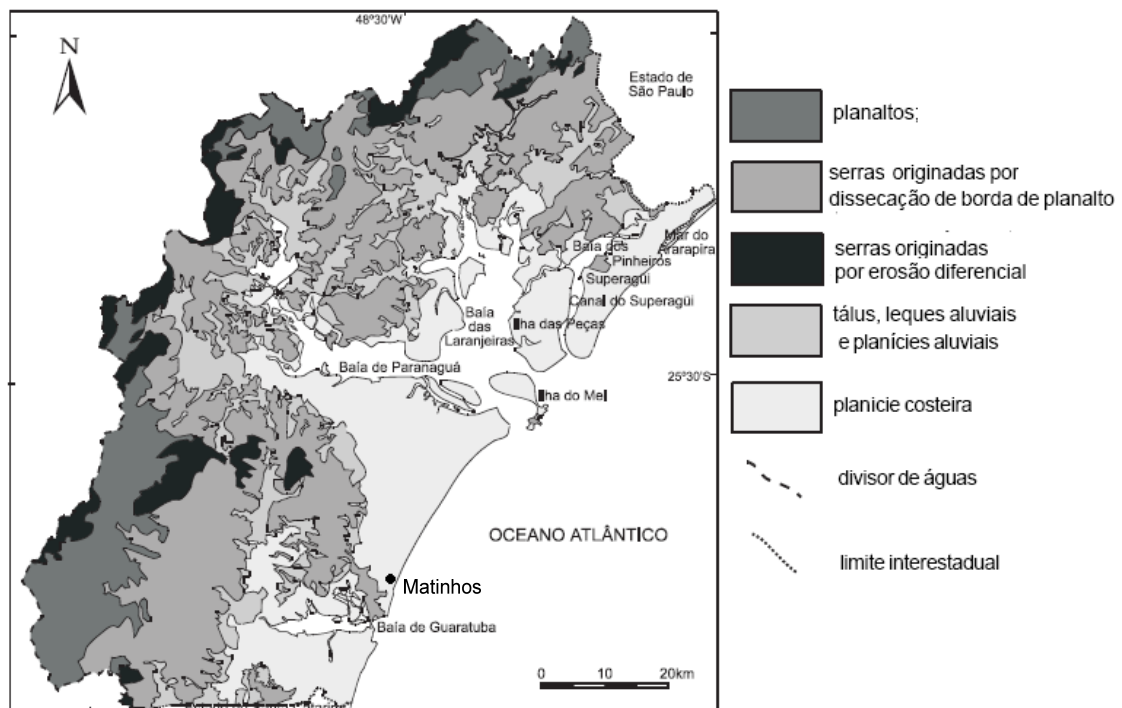



FIGURA 8- UNIDADES GEOMORFOLÓGICAS DA REGIÃO DO LITORAL PARANAENSE
FONTE: ANGULO (2004)

O litoral oceânico ou de mar aberto do Paraná apresenta forma retilínea com a orientação sul/sudoeste-norte/nordeste (SSW-NNE). Sua extensão é aproximadamente de 100 km, com os limites entre: Barra do Arapira (ao norte) e Barra do Saí (ao sul). As praias arenosas estendem-se ao longo de todo o litoral de mar aberto, interrompidas apenas por alguns pontais rochosos e pela embocadura das baías (ANGULO, 1993).

Os complexos estuarinos originam uma costa muito recortada. Enquanto a costa oceânica tem em torno de 100 km, as costas estuarinas têm aproximadamente 1300 km. A extensa linha de costa, associada à diversidade geológica, geomorfológica e dinâmica do litoral, propicia a formação de numerosos tipos de costa. Considerando a morfologia e a dinâmica de ondas, ventos, marés e correntes associadas, podem ser reconhecidos três tipos principais de costa: estuarinas, oceânica e de desembocadura (ANGULO, 1993).

As costas oceânicas são dominadas pela ação das ondas e se caracterizam por suas praias arenosas e dunas frontais. As costas estuarinas, pelas marés e apresentam planícies de maré com predomínio de manguezais. Já as costas de desembocadura, pela ação das ondas e das correntes de maré e se caracterizam por suas praias e por sua grande dinâmica. Neste tipo de costa são freqüentes os processos de erosão e sedimentação com acentuados deslocamentos da linha de costa (PIERRI *et al.*, 2006).

De acordo com a constituição geológica, a linha de costa pode ser classificada e dividida em dois tipos básicos: rochosa e sedimentar (FIGURA 9). A linha de costa rochosa ocorre quando as águas costeiras se encontram com as rochas pré-cambrianas do embasamento cristalino, principalmente granitos e diques de diabásio de idade juro-cretácea. No litoral paranaense sua extensão de linha de costa é aproximadamente 137 km. As costas sedimentares ocorrem quando as águas costeiras se encontram com sedimentos da planície costeira, com extensão aproximada de 1346 Km. Associadas a estas, ocorrem a planície de maré (1220 km) e as praias (126 km) (ANGULO, 1993).



(a)



(b)

FIGURA 9 – EXEMPLO DE LINHA DE COSTA ENCONTRADAS EM MATINHOS: ROCHOSA E SEDIMENTAR

FONTE: (a) TEDESCO *et al.* (2000); (b) O AUTOR

O QUADRO 2 apresenta a localização e extensão dos diferentes tipos de costa no Estado do Paraná, conforme esta classificação. Observando o QUADRO 2, verifica-se que a praia de Matinhos apresenta em sua linha de costa trechos rochosos e sedimentares, sendo a maior parte de sua extensão do tipo sedimentar, com praias oceânicas.

Tipo		Localização	Extensão (km)	Tipo		Localização		Extensão (km)		
Rochosa	estuarina	baía dos Pinheiros – canal do Superagüi	34,4	Sedimen- tar Com praias	estuarina	Baía de Paranaguá	ilha das Cobras	0,2		
		baía de Paranaguá	74,4		de desembocadura	Mar do Ararapira	Superagüi	8,2		
		baía de Guaratuba	9,8			canal do Superagüi	Superagüi	8,8		
	oceânica	ponta de Matinhos	0,3				ilha das Peças	4,0		
		ponta de Brejatuba	1,0			ilha das Peças		8,6		
		ilha Saí-Guaçu	0,8				Baía de Paranaguá	ilha do Mel	26,0	
			ilha da Figueira			1,0		Pontal do Sul	8,4	
		ilha dos Currais	1,3				praia Brava de Caiobá	0,8		
		ilhas Itacolomis	0,3				praia Mansa de Caiobá	1,2		
			de desembocadura				ilha das Palmas	2,0	Baía de Guaratuba	Prainha
		ilha do Mel					7,2	praia das Caieras		1,0
	ilha da Galheta	1,2				Guaratuba	0,4			
		morro de Caiobá e serra da Prata				2,5	rio Saí-Guaçu	barra do Saí		1,0
		morro de Guaratuba				0,8	oceânica	Superagüi (praia Deserta)		14,0
		com planície de maré			Mar do Ararapira	23,0		Pontal do Sul – Matinhos		29,0
	estuarina		baía dos Pinheiros – canal do Superagüi		155,1	Caiobá		2,2		
			baía de Paranaguá		814,9	Guaratuba		2,0		
			baía de Guaratuba		185,0	Brejatuba		9,2		
			rio Saí-Guaçu		20,0	Total			1483,0	
			de desembocadura		canal do Superagüi	16,0				
	baía de Paranaguá	6,0								

QUADRO 2 - LOCALIZAÇÃO E EXTENSÃO DOS DIFERENTES TIPOS DE COSTA NO ESTADO DO PARANÁ
FONTE: ANGULO (1996)

As classificações de costa, principalmente as referentes à estabilidade, fornecem subsídios para a ocupação da orla litorânea permitindo estabelecer, entre outras medidas, recuos mínimos para urbanização e tipos de ocupação para os diversos tipos de costa.

2.3.1 Histórico da ocupação do litoral para o balneário de Matinhos

O uso das praias no litoral centro-sul paranaense tem se caracterizado pela ocupação junto à linha de costa ou mesmo sobre a praia, pela destruição das dunas e paleodunas¹ frontais, pelo aterro de brejos e pela descaracterização de rios e córregos. Na sua ocupação não se levou em conta a morfologia e a dinâmica dos ambientes costeiros (PIERRI *et al.*, 2006).

Em 1920 não existiam construções próximas ao mar em Matinhos. Estima-se, que em torno de 1928, foram construídos na Praia de Matinhos, vestiários destinados à troca de roupa para o banho de mar (FIGURA 10). Os mesmos resistiram por pouco tempo, pois foram destruídos pela ação das marés e não foram reconstruídos.




FIGURA 10 - VESTIÁRIOS DESTINADOS À TROCA DE ROUPA PARA O BANHO DE MAR, CONSTRUÍDOS EM 1928
FONTE: BIGARELLA (1991)


¹ Paleodunas podem ser entendidas como dunas que não possuem mais atividades ou denominadas de inativas. Geralmente são recobertas pela vegetação, mas sua estrutura interna (estruturas sedimentares) indicam que a formação tem origem eólica.

A FIGURA 11 apresenta uma vista da praia de Matinhos, tomada do morro de Matinhos no início da década de 1930, demonstrando uma orla não ocupada por construções.




FIGURA 11 – PRAIA DE MATINHOS, INÍCIO DA DÉCADA DE 1930
FONTE: BIGARELLA (1991)

A ocupação desta praia começou a partir de 1936, com a construção de um hotel sobre a praia (FIGURA 12 (a)), onde, ao longo do tempo, outras construções foram sendo executadas próximas ao hotel e próximas à orla da praia (FIGURA 12 (b)).



(a)



(b)

FIGURA 12– HOTEL BEIRA-MAR DE RAINOLDO SCHEFFER
FONTE: BIGARELLA (1991)

O município de Matinhos possui 36 balneários. Entre eles, o que mais atrai investimentos e turistas durante o verão é o balneário de Caiobá. A ocorrência de erosão em Caiobá começou com a construção da Avenida Atlântica sobre a parte central da praia, nos anos 60 (PIERRI *et al.*, 2006). Na FIGURA 13 verifica-se que em 1953 foi efetuado o traçado da Avenida Atlântica sobre a linha de costa.



FIGURA 13 - FOTO AÉREA VERTICAL DE CAIOBÁ TOMADA EM 1953, (LINHA VERMELHA) TRAÇADO DA AVENIDA ATLÂNTICA, (LINHA AZUL) LINHA DE COSTA
FONTE: PIERRI *et al.* (2006)

Os processos de erosão foram detectados a partir da década de 70, quando a ocupação costeira foi intensificada próximo à praia. Muros com gabiões e concreto foram construídos para proteger as casas. Porém, após cada ano, durante as últimas décadas, as obras de engenharia foram destruídas pelas “ressacas” do mar.

No começo da década de 80, a erosão marinha foi observada na praia Brava de Caiobá, em consequência da ocupação da praia sobre a linha de costa. As fotografias históricas, 1981, duas de 1994 e uma 1995 (FIGURA 14) revelam a evolução da ocupação e seus efeitos de erosão costeira nas construções a partir de 1981 pelo fato de terem sido loteadas próximas ao mar.



FIGURA 14 – EVOLUÇÃO DO PROBLEMA EROSIVO AO LONGO DA ORLA DO MUNICÍPIO DE MATINHOS
 FONTE: ANGULO *et al.* (2000)

Passados 40 anos os problemas continuam. Segundo Pierri *et al.* (2006), o processo de erosão costeira tem retro-alimentação positiva, isto é, uma vez iniciado tende a crescer e é de difícil reversão. Quando os problemas se iniciam, dependendo do nível de ocupação da orla, a remoção das construções pode ser uma das melhores alternativas para a solução dos problemas. No Paraná foi realizada remoção de uma ocupação irregular na praia central de Matinhos, após a “ressaca” de maio de 2000, que destruiu várias residências. Após quatro anos, houve recomposição natural da praia e da duna frontal, como pode ser visto comparando as fotografias tomadas em épocas distintas apresentadas na FIGURA 15.



(a) (b)
 FIGURA 15 – (a) CASAS DESTRUÍDAS PELA RESSACA DE MAIO, 2000 EM MATINHOS (b) COM A RELOCAÇÃO DAS CASAS VERIFICA-SE A RECOMPOSIÇÃO NATURAL DA PRAIA E DA DUNA FRONTAL EM 2004
 FONTE: PIERRI *et al.* (2006)

Em maio de 2001, outra ressaca forte atinge a costa de Matinhos (FIGURA 16). Neste evento episódico, foram destruídas calçadas, boa parte da avenida beira-mar e algumas famílias de pescadores ficaram desabrigadas, segundo relatos apresentados em Krueger *et al.* (2002).



FIGURA 16– EFEITOS DA RESSACA NA COSTA DE MATINHOS (MAIO, 2001)
 FONTE: KRUEGER *et al.* (2002)

De acordo com Pierri *et al.* (2006) quando a ocupação ocorre muito próxima da linha de costa, embora não avance sobre a praia, pode causar os mesmos problemas, pois a linha de costa é uma feição que pode mover-se em direção ao continente durante períodos de ondas mais energéticas, e em direção ao mar, em períodos de ondas mais fracas. Este movimento da linha de costa vem acompanhado de mudanças do volume de areia da praia e das dunas frontais. Durante os períodos de ondas fracas,

ou de bom tempo, a areia tende a se acumular na parte emersa da praia e nas dunas frontais. Durante os períodos de ondas mais fortes, ou durante tempestades, grandes volumes de areia podem ser retirados das dunas e da parte emersa da praia, sendo depositada em barras submersas longitudinais à praia. A ocupação próxima da linha de costa e a remoção das dunas frontais impedem este ciclo de erosão-reconstrução e podem desencadear processos erosivos irreversíveis.

Destaca-se que em estudos realizados por Angulo e Soares (1994) chegou-se a hipótese que nas modificações observadas em algumas porções do litoral paranaense, como no caso de Matinhos, existem causas particulares associadas, não sendo possível atribuir somente a fatores que comandam a evolução das praias, como mudanças climáticas ou variações relativas no nível médio do mar.

Na FIGURA 17 são apresentadas algumas fotografias do local de estudo, tomadas em junho de 2007 e julho de 2008, quando se verificou *in loco* que os problemas de erosão costeira continuam presentes.



FIGURA 17 – FOTOGRAFIAS DA ÁREA DE ESTUDO DOS ANOS DE 2007 E 2008

2.4 MÉTODOS DE EXTRAÇÃO DA LINHA DE COSTA

Os mapeamentos históricos das linhas de costa normalmente são obtidos por diferentes técnicas em cada época conforme os equipamentos disponíveis. Nas seções seguintes são descritas as principais técnicas utilizadas para seu mapeamento na seguinte ordem: aerofotogrametria, imagens de satélites, LIDAR (*Light Detection and Ranging*) e posicionamento por satélites (por exemplo, GPS).

2.4.1 Aerofotogrametria

A linha de costa pode ser extraída de fotografias aéreas verticais. A sua extração neste tipo de técnica de mapeamento passa por dois processos. No primeiro, a linha de costa é identificada e traçada na fotografia; no segundo processo, a linha de costa é transferida para um mapa com base cartográfica em comum. A visão estereoscópica ajuda na identificação e traçado da linha de costa nas fotografias. Os estudos apresentados em Crowell *et al.* (1991) relataram que o erro envolvendo a locação de linhas de costa através de fotografias aéreas é em torno de 8 m. A FIGURA 18 apresenta a comparação temporal de imagens oriundas da aerofotogrametria detectando mudanças causadas pela expansão na região do Porto de Paranaguá, Paraná.




FIGURA 18 - FOTOS AÉREAS TEMPORAIS DO PORTO DE PARANAGUÁ, PARANÁ

Li *et al.* (2001) descrevem um estudo de caso usando fotografias aéreas (a cada 5 anos) para mapear e monitorar uma zona costeira integrando diferentes dados em um SIG. Destaca-se que a escolha de uma técnica para monitoramento da linha de costa depende do suporte econômico e da correta opção para a técnica de mapeamento.

Em Li *et al.* (2001), a linha de costa é digitalizada a partir de ortofotos aéreas. Nesse caso, o objetivo foi efetuar um estudo comparativo entre técnicas de extração de linhas de costa. Esse tipo de extração, utilizando a aerofotogrametria, é considerado como o mais acurado nesse estudo.

No projeto DIAMAT (2000) utiliza-se a técnica intitulada de “sistema fotogramétrico monorestituidor digital” para a realização da restituição monoscópica (monorestituição) (ver MITISHITA, 1997) das aerofotos para extração da linha de costa. A extração dessas linhas utilizando esta técnica depende de alguns fatores como: informações altimétricas, qualidade das fotos, escala da foto, distribuição e número de pontos de controle, e fotointerpretação do operador para delimitar a linha de costa.

As informações de linhas de costa extraídas no projeto DIAMAT (2000) através da monorestituição são utilizadas como material fonte.

2.4.2 Sensoriamento remoto por imagens de satélites

As imagens do satélite IKONOS com dois tipos de resoluções espaciais, 1 m pancromático e 4 m multiespectral, foram utilizadas em Li *et al.* (2001) para a extração da linhas de costa. Para avaliar os resultados é utilizada a linha de costa extraída da aerofotogrametria.

White e Asmar (1999) citam a importância do monitoramento e o cálculo de taxas de dinâmica da linha de costa. Imagens de satélite provenientes do *Landsat Thematic Mapper* (30 m de resolução espacial) são utilizadas para identificar mudanças no ambiente costeiro no decorrer do tempo. No projeto DIAMAT (2000), é utilizado uma

imagem IKONOS II com resolução de 1 m espacial e a variação espectral das bandas multiespectrais para a extração da linha de costa. Uma dificuldade relatada foi realizar a interpretação visual, visto que a imagem foi tomada logo após uma ressaca. Sendo assim, a interpretação visual foi prejudicada, pois os efeitos da destruição, em alguns casos, não provocaram alterações espectrais na imagem.

GONÇALVES *et al.* (2009) fez uso de uma imagem IKONOS II da região de Matinhos no Paraná para extrair a linha de costa e comparar os resultados encontrados. A imagem foi previamente classificada hierarquicamente através de regras nebulosas (*fuzzy rules*) (FIGURA 19). Após a classificação, foi feita a extração manual da linha de costa. Feito isso, a linha de costa extraída da imagem classificada foi comparada com a linha de costa adquirida através de levantamentos geodésicos por GPS, considerada como referência. Os resultados apresentam uma média aritmética de 18,1 m e desvio padrão com 9,9 m entre os desvios da linha de costa extraída (SR) e a considerada como referencia (GPS).




FIGURA 19 – IMAGEM CLASSIFICADA DE MATINHOS-PARANÁ
FONTE: GONÇALVES *et al.* (2009)

2.4.3 LIDAR (*Light Detection and Ranging*)

A técnica de *laser scanner* aerotransportado possibilita a obtenção de dados acurados e detalhes topográficos da superfície terrestre.

Os levantamentos com o LIDAR envolvem a combinação entre o *laser*, um dispositivo que grava os movimentos do avião e receptores GPS. O LIDAR pode efetuar levantamentos em áreas costeiras com precisão vertical de 8 a 15 cm e um conjunto de pontos espaçados em menos de 1 m (sem levar em conta os processos de extração da linha de costa). A partir destes dados a linha de costa pode ser extraída e ser utilizada em análises de variações na sua posição.

A FIGURA 20 e a FIGURA 21 apresentam dois exemplos obtidos com o LIDAR. Na FIGURA 20 tem-se o modelo digital do terreno com alguns elementos distorcidos (as construções) e duas linhas extraídas a partir deste modelo: a linha de costa e uma linha de interesse chamada de cordão dunar. A FIGURA 21 apresenta uma vista bidimensional deste mesmo modelo.




FIGURA 20 - MODELO DIGITAL DO TERRENO E EXTRAÇÃO DE LINHAS OBTIDAS PELO LIDAR
FONTE: GIBEAUT *et al.* (2007a)




FIGURA 21- DADOS OBTIDOS PELO LIDAR
FONTE: GIBEAUT *et al.* (2007a)

2.4.5 NAVSTAR-GPS

Desde 1996, o LAGE coleta dados usando o posicionamento por satélites GPS na costa do Estado do Paraná. Alguns projetos de pesquisa, projetos finais de graduação, dissertações de mestrado e teses de doutorado foram desenvolvidos envolvendo o tema sobre mapeamento costeiro.

Entre eles citam-se TEDESCO *et al.* (2000), SOUZA e KRUEGER (2002), BABINSCK (2006), ZEFERINO (2007), TANAJURA (2008) e MAIA e MAZUR (2008). As questões referentes ao posicionamento geodésico e avaliações de diferentes métodos de processamento de dados GPS utilizando diferentes estações bases e técnicas com aplicações em áreas costeiras podem ser encontradas em TANAJURA (2008). Em ZEFERINO (2007) faz-se uma comparação utilizando diferentes receptores GPS demonstrando suas limitações e precisões encontradas em um experimento prático para o mapeamento da linha de costa. SOUZA e KRUEGER (2002) avalia variações volumétricas temporais utilizando levantamentos GPS para uma determinada área costeira localizada no istmo da Ilha do Mel. TEDESCO *et al.* (2000) e BABINSKY (2006) realizam experimentos com a utilização do GPS para o mapeamento costeiro juntamente com análise de extração de linha de costa com o uso de sensoriamento

remoto e câmaras fotogramétricas de pequeno formato, respectivamente.

Na parte prática, em campo, é instalado um receptor geodésico de dupla frequência em uma estação base sobre um marco geodésico de coordenadas conhecidas referenciadas ao *datum* WGS-84, onde o receptor é configurado para coletar dados brutos a cada 3 segundos. Equipamentos móveis de dupla (ou simples) frequência configurados para um intervalo de gravação de dados de 3 segundos, no modo cinemático, com máscara de elevação de 10^0 são utilizados para percorrer a linha de costa a pé. A equipe de campo normalmente é composta de 4 ou mais integrantes do LAGE formada por alunos de graduação em Engenharia Cartográfica ou pós-graduação em Ciências Geodésicas com conhecimentos sobre levantamentos geodésicos estes, por sua vez, são previamente treinados e preparados para executar o mapeamento de linha de costa, conforme os critérios e objetivos de cada projeto. A FIGURA 22 mostra o uso de um receptor GPS em um levantamento relativo cinemático na área de estudo em Matinhos, Paraná. Esta forma de levantamento tem sido eficaz e acurada para pequenas áreas de estudo como no caso do balneário de Matinhos e Ilha do Mel (KRUEGER *et al.*, 2009).



FIGURA 22– LEVANTAMENTO RELATIVO CINEMÁTICO

MAIA e MAZUR (2008) organizam os dados temporais obtidos por GPS de campanhas e projetos de pesquisa anteriores na área de estudo. Além disso, novos levantamentos geodésicos com GPS são realizados com o objetivo de analisar as

variações na posição da linha de costa.

Krueger *et al.* (1998) fez uso do método de posicionamento relativo cinemático para o levantamento geodésico de linha de costa, a qual foi percorrida a pé. Em um dos levantamentos observou-se desvios padrão inferiores a 3 cm para as coordenadas (N, E), calculadas com o programa GPS PRISM.

Ribeiro (2005) apresenta tecnologias de Geoprocessamento para análise espaço-temporal em projetos de gerenciamento costeiro, enfatizando o uso do GPS para esta finalidade.

Na literatura internacional também é comum encontrar trabalhos como o de Ruggiero *et al.* (1999), destacando a importância do monitoramento das variações nas posições da linha de costa para o planejamento da urbanização costeira e ilustrando que o monitoramento da linha de costa pode ser conduzido utilizando a técnica RTK-GPS (*Real Time Kinematic - Global Positioning System*).

2.5 CONVERSÃO DOS DADOS TEMPORAIS PARA O MESMO SISTEMA DE REFERÊNCIA GEODÉSICO

Um banco de dados que contém informações sobre as variações posicionais da linha de costa e documentos cartográficos dos mais variados tipos devem estar no mesmo sistema geodésico de referência com o conhecimento do respectivo grau de acurácia.

No trabalho de Gibeaut *et al.* (2001), os dados temporais formados pelos mapas históricos, que não estão em meio digital, são digitalizados e as linhas de costa obtidas pelo LIDAR são transferidas para o *software ArcView GIS*. Em uma camada (*layer*) específica, é inserida uma ortofoto para direcionar o processo de registro das imagens e dos dados vetoriais. Uma vez no GIS, as informações são comparadas umas com as outras para verificar sua consistência.

2.6 CONSTRUINDO MODELOS EMPÍRICOS

De acordo com Montgomery *et al.* (2001) é freqüente a utilização de modelos por engenheiros e cientistas na formulação e solução de problemas. Algumas vezes, esses modelos são baseados no conhecimento científico de física, química ou de engenharia do fenômeno e, nesses casos, os modelos são chamados de modelos mecanísticos. Neste caso é possível citar, como exemplo, a lei de Ohm (Corrente = voltagem/resistência). Entretanto, existem situações em que duas ou mais variáveis de interesse estão presentes e o modelo com essas variáveis não é conhecido. Nesses casos é necessário construir um modelo relacionando as variáveis baseadas nos dados observados. Esse tipo de modelo é chamado de modelo empírico, o qual pode ser manipulado e analisado da mesma forma que um modelo mecanístico.

Nas próximas seções são apresentados os modelos de regressão linear, estimativa robusta e redes neurais artificiais.

2.6.1 Regressão linear simples

O caso de regressão linear simples considera um único regressor ou preditor x e uma variável dependente ou variável de resposta Y . Suponha que a relação verdadeira entre Y e x seja uma linha reta e que a observação Y em cada nível de x seja uma variável aleatória. O valor esperado de Y para cada valor de x é

$$E(Y / x) = \beta_0 + \beta_1 x. \quad (1)$$

A interseção β_0 e a inclinação β_1 são coeficientes desconhecidos da regressão. Considerando que cada observação Y possa ser descrita pelo modelo:

$$Y = \beta_0 + \beta_1 x + \varepsilon, \quad (2)$$

onde ε é o erro aleatório com distribuição normal (Gaussiana), média zero e variância σ^2 . Os erros aleatórios correspondendo a diferentes observações são também considerados variáveis aleatórias não correlacionadas.

Suponha-se n pares de observações $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$. A FIGURA 23 mostra um diagrama de dispersão dos dados observados e uma candidata para a linha estimada de regressão. As estimativas de β_0 e β_1 devem resultar em uma linha que seja (em algum sentido) o “melhor ajuste” para os dados. O cientista alemão Karl Gauss (1777-1855) propôs estimar os parâmetros β_0 e β_1 na EQUAÇÃO 2, de modo a minimizar a soma dos quadrados dos resíduos.

Esse critério de estimar os coeficientes de regressão é denominado de método dos mínimos quadrados. Expressando as n observações na amostra como:

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, i = 1, 2, \dots, n, \quad (3)$$

e sendo a soma dos quadrados dos desvios das observações em relação à linha de regressão dada por

$$L = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2. \quad (4)$$




FIGURA 23- CANDIDATA PARA A LINHA ESTIMADA DE REGRESSÃO

Os estimadores de mínimos quadrados de β_0 , β_1 , $\hat{\beta}_0$ e $\hat{\beta}_1$ (o símbolo “^” significa estimado) têm que satisfazer:

$$\frac{\partial L}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \quad (5)$$

$$\frac{\partial L}{\partial \beta_1} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) x_i = 0.$$

A simplificação dessas duas equações resulta

$$\begin{aligned}
 n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i \\
 \hat{\beta}_0 \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n y_i x_i .
 \end{aligned}
 \tag{6}$$

As EQUAÇÕES (6) são chamadas de equações normais dos mínimos quadrados. A solução para elas resulta nos estimadores de mínimos quadrados $\hat{\beta}_0$ e $\hat{\beta}_1$.

- Equações para o cálculo de regressão linear simples

As estimativas de mínimos quadrados da interseção e da inclinação no modelo de regressão linear simples são

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} . \tag{7}$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n y_i x_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}} . \tag{8}$$

Em que $\bar{y} = (1/n) \sum_{i=1}^n y_i$ e $\bar{x} = (1/n) \sum_{i=1}^n x_i$.

A linha estimada ou ajustada de regressão é, conseqüentemente

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x. \quad (9)$$

Cada par de observações satisfaz à relação

$$\bar{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + e_i, \quad i = 1, 2, \dots, n, \quad (10)$$

onde $e_i = y_i - \hat{y}_i$ é denominado de resíduo. Esse resíduo descreve o erro no ajuste do modelo para a i -ésima observação y_i .

Em termos de notação é em alguns casos conveniente dar símbolos especiais ao numerador e ao denominador da equação (8). Tendo como dados (x_1, y_1) , (x_2, y_2) , ..., (x_n, y_n) considera-se

$$\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}} \quad (11)$$

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} \quad (12)$$

$$S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n y_i x_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n} . \quad (13)$$

2.6.2 Estimativa robusta

Outra forma de tratar matematicamente a solução do modelo de regressão linear simples sem utilizar as fórmulas convencionais descritas na seção anterior é através do método de ajustamento de observações conhecido no Brasil, como Paramétrico (ver, por exemplo, DALMOLIN, 2004) ou na Alemanha, como Gauss-Markov. O equacionamento desta opção de solução será descrito a seguir, juntamente com a descrição da estimativa robusta.

O modelo de regressão linear comumente utilizado em modelos de predição de linha de costa, expresso na EQUAÇÃO 9, agora será denominado e descrito na forma matricial por

$$\mathbf{y} = a\mathbf{x} + b , \quad (14)$$

onde \mathbf{y} e \mathbf{x} são os vetores de regressão linear, enquanto que a e b são os coeficientes desconhecidos de regressão linear. A EQUAÇÃO 14 pode ser expressa em termos das observações e dos parâmetros por

$$\mathbf{y} = \mathbf{A}\beta + \varepsilon , \quad (15)$$

com \mathbf{y} sendo $n \times 1$ vetor de colunas das observações, $\mathbf{A} = \frac{\partial F}{\partial \beta}$ é a matriz das derivadas parciais da função (EQUAÇÃO 14) em relação aos parâmetros, sendo $n \times m$ (aqui $m = 2$), $\beta = [a \ b]'$ (onde o símbolo “'” significa transposta) é o vetor dos parâmetros da regressão linear $m \times 1$ e ε o vetor $n \times 1$ dos erros das observações. A EQUAÇÃO 15 pode agora ser expressa na forma do modelo de estimação Gauss-Markov como sendo:

$$\mathbf{y} = \mathbf{A}\beta + \varepsilon; \quad \varepsilon \sim (0, \sigma_0^2 \mathbf{W}^{-1}), \quad (16)$$

onde a solução é dada por

$$\hat{\beta} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{y}, \quad (17)$$

com a dispersão $D\{\hat{\beta}\} = \hat{\sigma}_o^2 (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1}$ e $\hat{\sigma}_o^2 = (\varepsilon^T \mathbf{W} \varepsilon) / (n - m)$. Aqui, $\hat{\sigma}_o^2$ é a variância da unidade peso e \mathbf{W} é a matriz $n \times n$ dos pesos.

A solução da regressão linear, expresso na EQUAÇÃO 17, pode ser aplicada quando não existe nenhum erro grosseiro² e $\hat{\beta}$ se torna um estimador não tendencioso de β desde que a esperança $E\{\hat{\beta}\} = \beta$. Com os erros grosseiros nas observações, entretanto, tem-se

² Os erros grosseiros são observações que não podem ser consideradas pertencentes a uma mesma amostra a partir de uma determinada distribuição. Normalmente, o parâmetro medidor da magnitude dos erros é o desvio-padrão. No caso do erro ser superior a três desvios-padrões pode ser considerado como erro grosseiro. Existem os chamados *outliers* que também são considerados erros grosseiros, porém com uma magnitude menor que a considerada acima e são de difícil detecção (DALMOLIN, 2004).

$$\mathbf{y} = E\{\mathbf{y}\} + \zeta + \varepsilon, \quad (18)$$

onde ζ é o vetor tendencioso $n \times 1$ sobre o vetor das observações \mathbf{y} . Considerando $\mathbf{y} = \bar{\mathbf{y}} + \delta\mathbf{y}$, a solução da EQUAÇÃO 18 a partir da EQUAÇÃO 17 é escrita por:

$$\hat{\beta} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \bar{\mathbf{y}} + (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \delta\mathbf{y}, \quad (19)$$

com a esperança

$$E\{\hat{\beta}\} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \bar{\mathbf{y}} + (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \zeta = \beta + \gamma = \beta_o \quad (20)$$

e $\bar{\mathbf{y}} = E\{\mathbf{y}\}$; $\delta\mathbf{y} = \zeta + \varepsilon$. Torna-se evidente que $\hat{\beta}$ é o estimador tendencioso de β com o termo $(\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \zeta$. Considerando $\gamma = -\delta\beta$, a EQUAÇÃO 20 fica

$$\beta = \beta_o + \delta\beta. \quad (21)$$

O modelo de estimação robusta é definido da seguinte maneira: considera-se x_1, x_2, \dots, x_n como sendo variáveis aleatórias independentes, assumindo-se serem elas distribuídas de acordo com a distribuição normal descrita pela função de densidade de

probabilidade $F_o(x)$. Se uma fração κ ($0 < \kappa < 1$) de observações é contaminada com erros grosseiros, então a nova distribuição será representada por (HUBER, 1964):

$$F(x) = (1 - \kappa)F_o(x) + \kappa H(x), \quad (22)$$

onde $H(x)$ é a desconhecida distribuição contaminada. O processo de estimação robusta estima os parâmetros desta configuração de forma que a influência dos erros grosseiros na estimativa final dos parâmetros é significativamente reduzida. Ao adotar o processo de estimação robusta, procura-se um método rigoroso de ajustamento que resolva a EQUAÇÃO 19 e retorne resultados o mais próximo possível da EQUAÇÃO 17. Uma das vantagens de usar o método de estimativa robusta é que ela não descarta de imediato a observação considerada como erro grosseiro e sim isola seu efeito através da mudança de peso. O método iterativo de peso providencia um significado para mudar o peso nas observações inapropriadas (ADUOL, 1994).

Nesta abordagem, os pesos das observações são considerados como funções de ambos os casos variâncias observacionais e resíduos observacionais. Na EQUAÇÃO 16, a matriz dos pesos é definida como

$$\mathbf{W} = \Sigma^{-1}, \quad (23)$$

com Σ sendo a matriz covariância das observações. Este peso é modificado no método robusto iterativo dos pesos no qual a EQUAÇÃO 23 leva em consideração os resíduos. A EQUAÇÃO 23 é re-escrita como

$$\mathbf{W} = (\mathbf{R}^2 + \Sigma)^{-1}, \quad (24)$$

onde

$$\mathbf{R} = \begin{bmatrix} v_1 & 0 & \cdot & 0 \\ 0 & v_2 & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & v_n \end{bmatrix} \quad (25)$$

e v_1, v_2, \dots, v_n são os resíduos observacionais da EQUAÇÃO (16) sendo

$$\hat{\mathbf{v}} = \mathbf{y} - \mathbf{A}\hat{\boldsymbol{\beta}}. \quad (26)$$

Os valores v obtidos da EQUAÇÃO (26) são reintroduzidos na EQUAÇÃO (24) para obter uma nova matriz dos pesos \mathbf{W} . O processo para estimar $\hat{\boldsymbol{\beta}}$ é repetido até um nível suficiente de convergência que pode ser atenuado. Nesta abordagem iterativa, os novos valores da matriz peso \mathbf{W} são aqueles usados na solução da regressão linear na EQUAÇÃO 17.

Este método faz uso do fato que qualquer erro grosseiro nas observações irá se manifestar por si próprio nos resíduos estimados que tende ser maior quando comparado com os demais devido ao efeito dos erros grosseiros. Na re-estimação dos elementos da matriz peso \mathbf{W} , um relativo resíduo grande resulta em um relativo peso baixo para a respectiva observação. O processo segue fornecendo pesos baixos para as observações que contem erros grosseiros. Fazendo isso, reduz-se o efeito das observações ruins sobre a quantidade estimada.

2.6.3 Redes neurais artificiais

As Redes Neurais Artificiais (RNAs) são inspiradas no funcionamento do cérebro humano para tentar emular sua forma inteligente de processar informações. A utilização das RNAs para solução de problemas é uma ferramenta atrativa e passa por um procedimento usual onde inicialmente existe a etapa de aprendizagem, onde um conjunto de exemplos é apresentado para a RNA, a qual extrai as características necessárias para representar a informação fornecida e estas informações e características são utilizadas posteriormente para gerar respostas para o problema (KRÖSE e SMAGT, 1996; BRAGA *et al.*, 2000).

A capacidade de uma RNA em aprender através de um conjunto reduzido de exemplos mapeando relações de entrada e saída, e posteriormente dando respostas coerentes para dados não conhecidos, demonstra o poder das RNA como ferramentas computacionais para solução de problemas complexos. O processo de treinamento de uma RNA inicia com uma fundamentação em casos conhecidos, considerados como reais. A partir destas entradas, ela aprende a sistemática necessária para o processamento, sendo capaz de extrair regras básicas, consideradas como o conjunto de pesos em função dos dados reais, o que a diferencia da computação convencional, que necessita de algoritmos com regras rígidas e pré-fixadas (HAYKIN, 1999).

Várias são as aplicações para RNAs, entre elas encontram-se a utilização para: reconhecimento de padrões (WALDEMARK *et al.*, 1995), agrupamento de dados (GUERRA, 2006), processamento de sinais (FUJII, 1993), telecomunicações (GEROMEL, 2003), robótica (KUBOTA *et al.*, 2003), tomada de decisões (MACIEL, 2005), predição (HAYATI e SHIRVANY, 2007) e exemplos de aplicações na área de Ciências Geodésicas (RIBEIRO, 2003, WANDRESEN, 2004, SOUZA, 2006, VAFEIDIS *et al.* 2007).

O modelo biológico do sistema nervoso é constituído de um corpo celular chamado de neurônio, que possuem a capacidade de realizar processamentos de informações como reconhecimento de padrões, percepção e controle da locomoção do corpo humano (ARBIB, 2003).

O neurônio biológico (FIGURA 24) ou célula nervosa é formado basicamente por três regiões: o corpo celular, os dendritos e o axônio.




FIGURA 24 - NEURÔNIO BIOLÓGICO
ADAPTADO DE ARBIB (2003)

Um conjunto de fibras é ligado ao corpo celular e uma delas se chama axônio que possui um conector cilíndrico, que carrega o impulso de resposta do neurônio, que é transmitido para o dendrito de outro neurônio. Os dendritos têm a função de receber as informações através de longos axônios dos outros neurônios e enviar as mesmas para o corpo celular, o qual recebe os estímulos vindos dos dendritos, tem a capacidade de calcular se estes estímulos ultrapassam um limiar (*threshold*) de excitação e a resposta é enviada para o axônio. As ramificações distribuem informações no final do axônio para outros neurônios vizinhos. Através de sinapses são realizadas ligações com outros neurônios, que são conectados a um dendrito de um neurônio receptor. A sinapse dispara uma substância química quando é excitada pelo impulso do axônio. Esta substância é transmitida entre dois neurônios vizinhos, conforme as excitações (ou inibições) que as células vizinhas transmitem para a célula em consideração que processa a informação novamente e transmite via seu axônio. O cérebro humano possui aproximadamente 100 bilhões de neurônios e 100.000 bilhões de sinapses, ou seja, um sistema complexo. Porém, suas características básicas serviram de inspiração para criação das RNAs (PEREIRA e RAO, 2009).

Para configuração e elaboração de uma RNA devem ser especificadas: as características dos neurônios, a topologia e as regras de treinamento. A adaptação dos pesos iniciais e a aprendizagem do seu comportamento são especificadas pelas regras de treinamento. Os algoritmos de treinamento (ou aprendizado) de uma RNA têm a característica de ajustar de forma iterativa os pesos das conexões entre os neurônios até que os pares de entradas e saídas, no caso de aprendizado supervisionado, por exemplo, esperados sejam obtidos e as relações de causa e efeito possam ser estabelecidas. Quando a configuração de um determinado problema apresentado às RNA muda e o modelo do desempenho não é mais adequado a situação, é possível submeter a RNA a mais treinamentos, com novas condições de entrada e saída para a melhora do seu desempenho (KRÖSE e SMAGT, 1996; HAYKIN, 1999).

O primeiro modelo artificial de um neurônio biológico foi proposto no trabalho pioneiro de Warren McCulloch e Walter Pitts, em 1943. O modelo esquemático de um neurônio artificial proposto por McCulloch-Pitts é uma simplificação do que se sabia a respeito do neurônio biológico. A FIGURA 25 apresenta o modelo geral de um neurônio artificial e nela é possível identificar os três elementos básicos (KRÖSE e SMAGT, 1996; HAYKIN, 1999; ARBIB, 2003; BRAGA *et al.*, 2000).

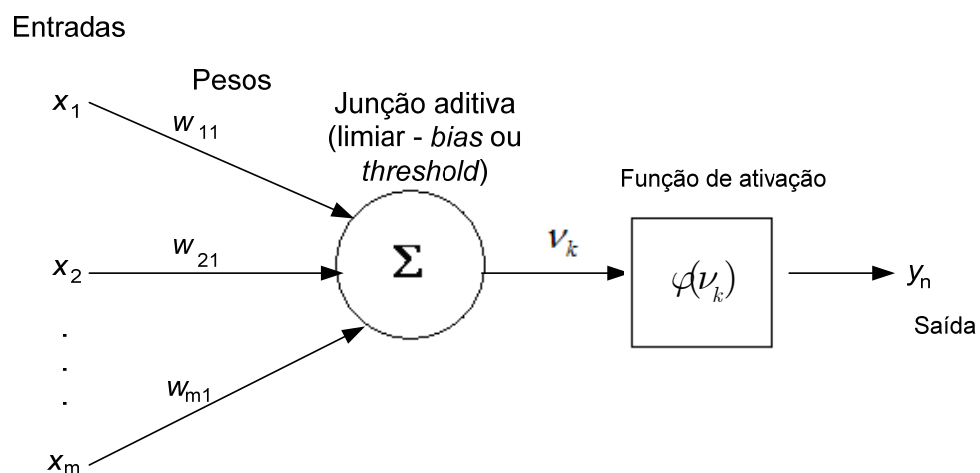


FIGURA 25 – MODELO GERAL DE UM NEURÔNIO ARTIFICIAL
ADAPTADO DE HAYKIN (1999)

O primeiro elemento é um conjunto de sinapses ou elos de conexão, cada qual caracterizada por um peso w_{kj} , com $k = 1$ e $j = 1, 2, \dots, m$.

O segundo elemento diz respeito a um somatório para os sinais de entrada, ponderado pelas sinapses do neurônio (combinação linear), tal que

$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j. \quad (27)$$

O terceiro elemento é uma função de ativação, que restringe a amplitude de saída de um neurônio, limitando o intervalo de saída para um valor finito

$$y_k = \varphi(v_k). \quad (28)$$

Um neurônio k pode ser descrito matematicamente através das EQUAÇÕES 27 e 28, onde φ representa a função de ativação do neurônio artificial. A função de ativação existe para buscar um ajuste ótimo ou modelo para um problema.

Vários outros modelos, após o trabalho de McCulloch e Pitts, foram derivados permitindo saídas, não necessariamente iguais a 0 ou 1 e com diferentes funções de ativação.

A FIGURA 26 apresenta três tipos de funções de ativação. Em (a) a função logística sigmóide (*logsig*); (b) a função tangente hiperbólica (*tansig*); e em (c) a função linear de ativação (*purelin*).




FIGURA 26 – FUNÇÕES DE ATIVAÇÃO
 FONTE: NEURAL NETWORK TOOLBOX (2008)

A função logística sigmóide expressa na EQUAÇÃO 29 pode assumir valores entre 0 e 1, onde a é o parâmetro de inclinação da função sigmóide e v é o valor de ativação do neurônio,

$$f(v) = \frac{1}{1 + e^{(-av)}} \quad (29)$$

A EQUAÇÃO 30 representa a função tangente hiperbólica, assumindo valores entre 1 e -1, onde a é o parâmetro de inclinação da curva, b representa os limites inferiores e superiores, e v é o valor de ativação, ou seja,

$$f(v) = a \frac{e^{(bv)} - e^{(-bv)}}{e^{(bv)} + e^{(bv)}} \quad (30)$$

A função de ativação linear é definida pela EQUAÇÃO 31, onde a é um número real que define a saída linear para os valores de entrada, y é a saída e x é a entrada. Assim,

$$y = ax. \quad (31)$$

Um importante conceito de uma RNA é a definição da *arquitetura*, ou seja, a forma com que os neurônios em uma rede podem estar organizados, sendo este um parâmetro importante que restringe o tipo de problema que pode ser tratado na rede. RNAs com uma camada única de neurônios, por exemplo, só conseguem resolver problemas linearmente separáveis. As redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal (BRAGA *et al.*, 2000).

2.6.3.1 Arquitetura

É possível separar três classes de arquiteturas de RNAs (PEREIRA e RAO, 2009):

1. *Single-Layer Feedforward Networks* (redes de camadas únicas, FIGURA 27): os neurônios são organizados em uma única camada. Nelas existe uma camada de entrada de neurônios fontes, projetada para uma camada de saída de neurônios, mas não vice-versa.
2. *Multilayer Feedforward Networks* (redes de multicamadas, FIGURA 28): Possuem uma ou mais camadas escondidas. Os neurônios, em cada uma das camadas, têm como entrada, a saída dos neurônios procedentes apenas da camada anterior.




FIGURA 27 – REDES DE CAMADAS SIMPLES
 FONTE: PEREIRA e RAO (2009)




FIGURA 28 - REDES MULTICAMADAS
 FONTE: PEREIRA e RAO (2009)

3. *Recurrent Networks* (redes recorrentes, FIGURA 29): ao menos um neurônio conecta-se com a camada precedente criando um laço de realimentação (*feedback loop*).

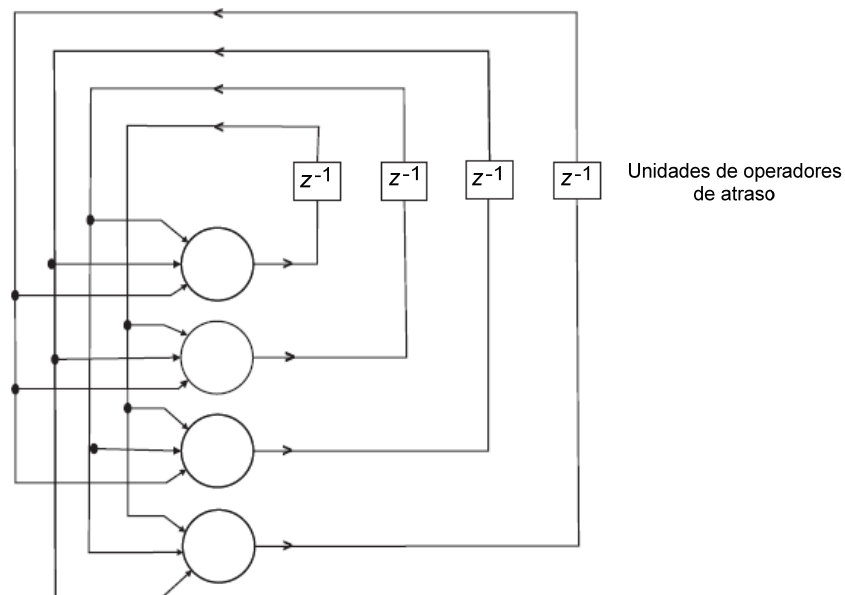


FIGURA 29 – REDES RECORRENTES
 FONTE: PEREIRA e RAO (2009)

Na definição de arquitetura encontram-se os seguintes parâmetros (BRAGA *et al.*, 2000):

- número de camadas da rede;
- números de neurônios em cada camada;
- tipo de conexão entre os neurônios; e
- topologia da rede.

A FIGURA 30 representa alguns exemplos de arquiteturas de RNAs.

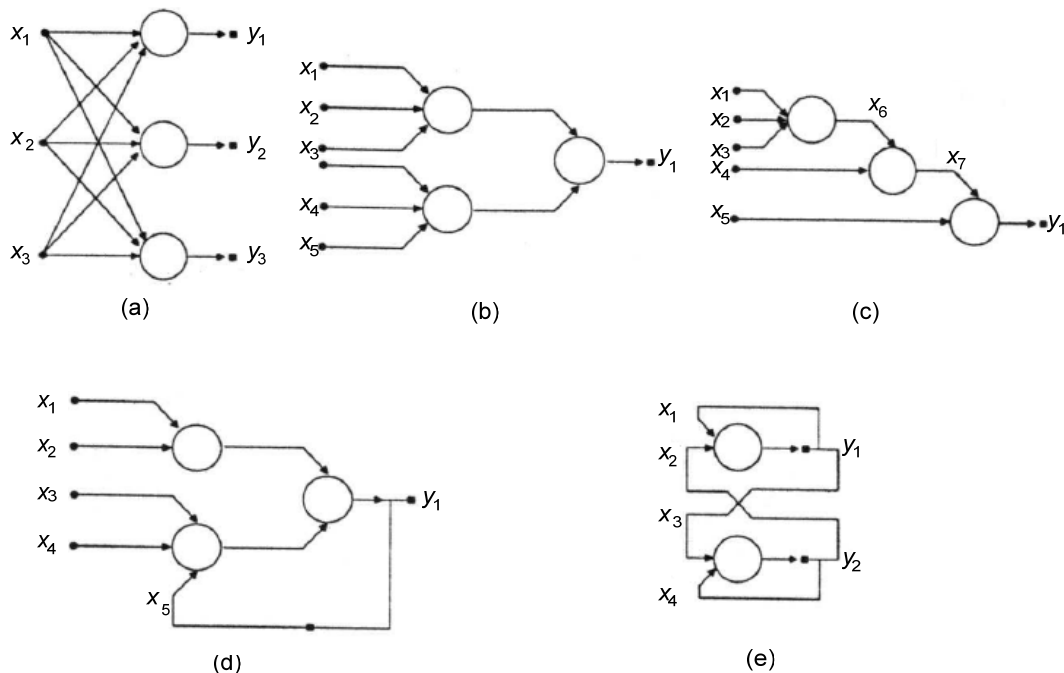


FIGURA 30 – EXEMPLOS DE ARQUITETURA DE REDES NEURAIS ARTIFICIAIS
 FONTE: BRAGA *et al.* (2000)

Na FIGURA 30 apresenta-se os seguintes parâmetros:

1) Quanto ao número de camadas

- Redes de camada única: onde só existe um neurônio entre qualquer entrada e qualquer saída (FIGURA 30 (a), (e));
- Redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída da rede (FIGURA 30 (b), (c), (d)).

2) Tipos de conexões nos neurônios:

- *Feedforward*, ou acíclica: a saída de um neurônio na *i-ésima* camada da rede não pode ser usada como entrada de neurônios em camadas de índice menor ou igual a *i* (FIGURA 30 (a), (b), (c));
- *Feedback*, ou cíclica: a saída de algum neurônio na *i-ésima* camada da rede é usada como entrada de neurônios em camadas de índice menor ou igual a *i* (FIGURA 30 (d), (e)).

3) Quanto a sua conectividade

- Rede fracamente (ou parcialmente) conectada (FIGURA 30 (b), (c), (d));
- Rede completamente conectada (FIGURA 30 (a), (e)).

2.6.3.2 Aprendizado

As RNAs têm a capacidade de aprender por meio de exemplos e fazer interpolações e extrapolações do que aprenderam. Neste tipo de aprendizado conexionista, não se procura obter regras, mas sim determinar a intensidade de conexões entre neurônios. O conjunto de procedimentos bem-definidos para adaptar os parâmetros de uma RNA, para que a mesma possa aprender uma determinada função, se chama algoritmo de aprendizado. Eles basicamente se diferem pela maneira pela qual o ajuste dos pesos é feito. Sendo assim, existem um conjunto de técnicas que são representadas por diversos algoritmos, onde cada um tem suas características que podem apresentar vantagens e desvantagens na solução de problemas (BRAGA *et al.*, 2000).

Em Mendel e McLaren (1970) e Braga *et al.* (2000), a aprendizagem é definida como “o processo pelo qual os parâmetros de uma rede neural são ajustados mediante uma forma continuada de estímulo, pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada pela maneira particular como ocorrem os ajustes nos parâmetros.”

Existem diversos tipos de métodos para treinamento de redes e estes são agrupados em dois tipos: o aprendizado supervisionado e o aprendizado não supervisionado. Outros dois paradigmas conhecidos são os de aprendizado por reforço (que é um caso particular de aprendizado supervisionado) e aprendizado por competição (que é um caso particular de aprendizado não supervisionado) (BRAGA *et al.*, 2000).

O método de aprendizado supervisionado (FIGURA 31) das RNAs, tanto de neurônios com pesos como de neurônios sem pesos têm este nome, em função da entrada e saída desejadas para a rede serem fornecidas por um supervisor (professor)

externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos (HAYKIN, 1999).




FIGURA 31 – APRENDIZADO SUPERVISIONADO
ADAPTADO DE: HAYKIN (1999)

A rede tem sua saída corrente (calculada) comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual. A cada padrão de entrada submetido à rede compara-se a resposta desejada (que representa uma ação ótima para ser realizada pela rede) com a resposta calculada, ajustando-se os pesos das conexões para minimizar o erro. A minimização da diferença é incremental, já que pequenos ajustes são feitos nos pesos a cada etapa de treinamento. A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento. A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e a sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* (BRAGA *et al.*, 2000).

O aprendizado supervisionado pode ser descrito basicamente de duas formas: *off-line* e *on-line*. Para treinamento *off-line*, os dados do conjunto de treinamento não mudam, e uma vez obtida uma solução para a rede, esta deve permanecer fixa. Caso novos dados sejam adicionados ao conjunto de treinamento, um novo treinamento, envolvendo também os dados anteriores, deve ser realizado para se evitar a interferência no treinamento anterior. No aprendizado *on-line*, o conjunto de dados

muda continuamente, e a rede deve estar em contínuo processo de adaptação (BRAGA *et al.*, 2000).

No caso do aprendizado não supervisionado, não há um professor para acompanhar o processo de aprendizado. Este método pode ser ilustrado pela FIGURA 32. Este tipo de aprendizado tem semelhanças com o aprendizado supervisionado e o aprendizado dos seres humanos. Porém, muitos dos sistemas biológicos ocorrem por aprendizado não-supervisionado, como é o caso dos estágios iniciais da visão e audição. Nestes algoritmos somente são fornecidos parâmetros de entrada para a rede, ao contrário do supervisionado que possui pares de entrada e saída. No momento em que a RNA estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se uma habilidade de formar representações internas para codificar características de entrada e criar novas classes ou grupos automaticamente. É importante salientar que a abundância de dados neste tipo de aprendizado é muito importante, pois caso contrário fica difícil estabelecer algum padrão ou características dos dados de entrada (BRAGA *et al.*, 2000).




FIGURA 32 – APRENDIZADO NÃO-SUPERVISIONADO
ADAPTADO DE: HAYKIN (1999)

O aprendizado não-supervisionado pode possuir diferentes arquiteturas. Por exemplo, podem constituir-se em uma camada de entrada, uma camada de saída, conexões *feedforward* da entrada para saída e conexões laterais entre os neurônios da camada de saída. Outro exemplo possível é uma rede *feedforward* com múltiplas camadas, em que a livre organização precede na base de camada por camada. Em ambos os processos, a idéia é modificar repetidamente o peso sináptico de todas as conexões do sistema em resposta ao conjunto de entradas (BRAGA *et al.*, 2000).

2.6.3.3 Perceptron multicamadas

As redes perceptron multicamadas (MLP, *multilayer perceptron*) apresentam um poder computacional maior do que as redes sem camadas intermediárias, pois possuem a capacidade de tratar dados que não são linearmente separáveis (HAYKIN, 1999; ARBIB, 2003). Um dos principais aspectos deste tipo de rede está relacionado com a função de ativação utilizada (BRAGA *et al.*, 2000).

A MLP consiste de um conjunto de unidades sensoriais que compõe a camada de entrada, uma ou mais camadas ocultas de neurônios e uma camada de saída. O sinal de entrada se propaga para frente, camada por camada pela rede (KRÖSE e SMAGT, 1996).

2.6.3.4 Modelo neural

A FIGURA 33 descreve um modelo neural com R entradas. Cada entrada recebe um peso apropriado denominado como W . A soma dos pesos de entrada e o bias formam a entrada para a função de transferência f . Os neurônios podem ser gerados com diferentes formas de transferência f para gerar uma saída, R é o número de elementos no vetor de entrada.

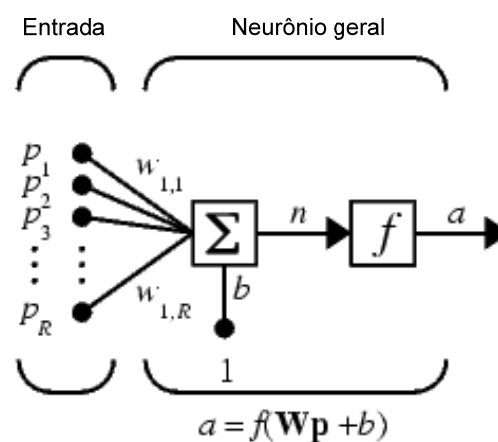


FIGURA 33 – MODELO GERAL DE ARQUITETURA MLP
FONTE: NEURAL NETWORK TOOLBOX (2008)

As MLP freqüentemente utilizam a função logarítmica-sigmóide como função de transferência, onde as saídas geradas estão entre 0 e 1.

A FIGURA 34 (a) representa a arquitetura da rede *Feedforward* com uma camada simples com S neurônios com a função logarítmica-sigmóide composto de R entradas, e em (b) a representação de um diagrama de uma camada.

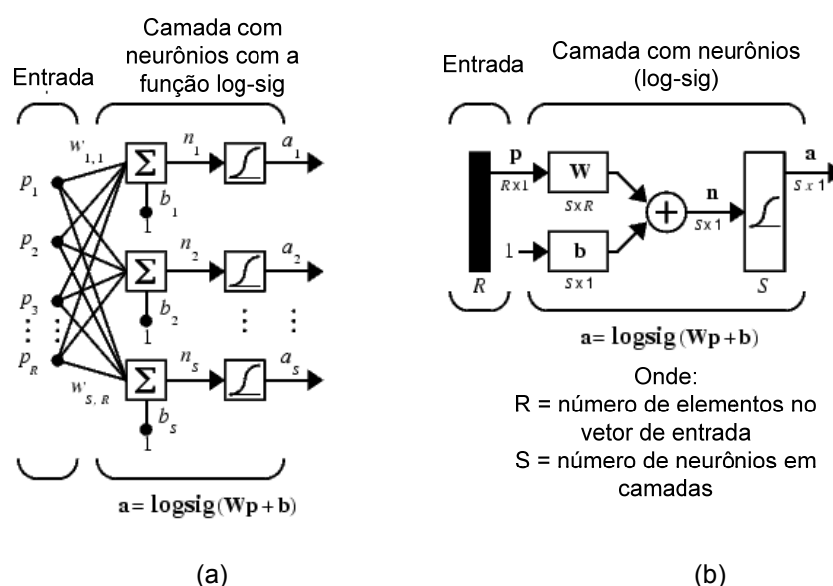


FIGURA 34— ARQUITETURA DA REDE *FEEDFORWARD*
 FONTE: NEURAL NETWORK TOOLBOX (2008)

As RNAs *feedforward* freqüentemente contêm uma ou mais camadas escondidas de neurônios sigmóides seguidos de uma camada de saída de neurônios lineares. Os neurônios múltiplos com função de transferência não linear permitem que a rede aprenda relações não-lineares e lineares entre os vetores de entrada e saída. O vetor de saída permite que a rede tenha valores fora do intervalo -1 até +1. Por outro lado, se saídas desejadas da rede forem valores numéricos no intervalo entre 0 e 1, deve ser usado na camada de saída uma função de transferência como a logarítmica-sigmóide.

Para redes neural multicamadas, o número de camadas determina o expoente na matriz dos pesos. A FIGURA 35 representa a notação para arquitetura composta por

duas camadas utilizando as seguintes funções: tangente-sigmóide e linear. E esta rede pode ser usada como solução aproximada de uma função geral. Ou seja, ela pode aproximar qualquer função com um número finito de descontinuidades arbitrariamente bem, dado suficientes neurônios na camada oculta.

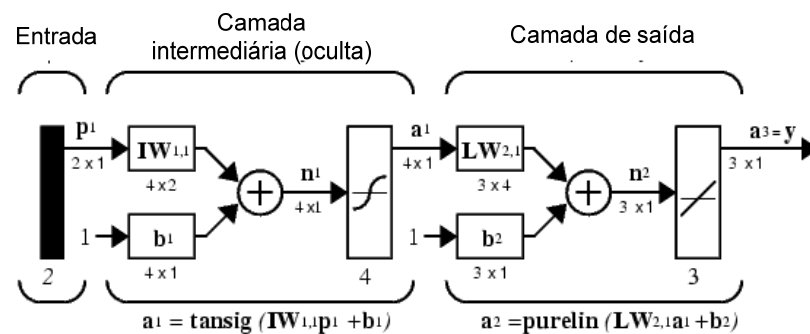


FIGURA 35– EXEMPLO DE REDE DE DUAS OU MAIS CAMADAS
FONTE: NEURAL NETWORK TOOLBOX (2008)

Para treinar uma rede *feedforward* são necessários configurar alguns argumentos, entre os quais se encontram os principais:

- A matriz com amostras formando os R elementos do vetor de entrada;
- A matriz de amostra com S elementos de vetores alvos;
- O número de camadas escondidas;
- As funções de transferência para as camadas;
- A função de treinamento.

As amostras de entrada e saída são usadas para inicializar a rede conforme as dimensões e parâmetros de entrada e saída. Antes do treinamento, os pesos podem ser iniciados automaticamente ou não.

2.6.3.5 Rede parcialmente recorrente de Elman

Nas redes de Elman, além das unidades de entrada, intermediárias e de saída, há também as unidades chamadas de contexto, como no caso das redes parcialmente recorrentes em geral (FIGURA 36). As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem. As unidades de entrada são apenas unidades de armazenamento que passam os sinais sem modificá-los. As unidades de saída são unidades lineares que somam os sinais que recebem. As unidades intermediárias podem ter funções de ativação lineares ou não-lineares, e as unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo. As conexões *feedforward* são modificáveis, e as conexões recorrentes são fixas, motivo pelo qual a rede de Elman é apenas parcialmente recorrente (BRAGA *et al.*, 2000).

Em um intervalo de tempo específico k , as ativações das unidades intermediárias (em $k - 1$) e as entradas correntes (em k) são utilizadas como entradas da rede. Em um primeiro estágio, *feedforward*, estas entradas são propagadas para frente para produzir as saídas. Posteriormente, a rede é treinada com o algoritmo de aprendizagem da retropropagação do erro padrão. Após este passo de treinamento, as ativações das unidades intermediárias no tempo k são reintroduzidas, pelas ligações recorrentes nas unidades de contexto, sendo salvas nestas unidades para o próximo passo do treinamento ($k + 1$). No início do treinamento, as ativações das unidades intermediárias são desconhecidas e, geralmente são iniciadas para a metade do valor máximo que as unidades intermediárias podem ter (BRAGA *et al.*, 2000).




FIGURA 36 – REDES DE ELMAN
FONTE: (BRAGA *et al.*, 2000).

Na FIGURA 37 apresenta-se a rede de Elman, com duas camadas, com realimentação da primeira camada de saída para a primeira camada de entrada.

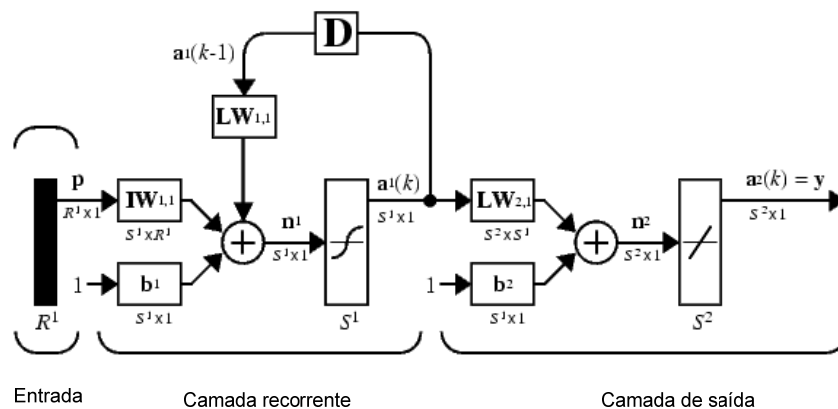


FIGURA 37 – EXEMPLO DA ARQUITETURA DE ELMAN
FONTE: NEURAL NETWORK TOOLBOX

As redes de Elman têm neurônios com a função tangente hiperbólica nas camadas ocultas (recorrentes) e neurônios com a função linear de ativação na camada de saída. Quando a função a ser ajustada aumenta sua complexidade, é necessário aumentar o número de neurônios nas camadas ocultas.

Sua diferença para as redes convencionais está exatamente na conexão recorrente da primeira camada. O atraso nesta conexão armazena valores do passo inicial, que pode ser usado no passo corrente.

2.6.3.6 O algoritmo de aprendizagem retropropagação do erro

O algoritmo mais popular das RNA é o de retropropagação do erro (*error back-propagation*), cuja fundamentação é corrigir os erros conforme a regra de aprendizagem. A maioria dos métodos de aprendizado para RNA do tipo MLP utiliza variações deste algoritmo (BRAGA *et al.*, 2000).

Sua aprendizagem consiste em dois passos obtidos pelas diferentes camadas da rede, conforme o sentido (FIGURA 38): um passo à frente, a propagação (*forward*), e um passo para trás, a propagação (*backward*).




FIGURA 38 – FLUXO DE PROCESSAMENTO DO ALGORITMO RETROPROPAGAÇÃO DO ERRO
FONTE: (BRAGA *et al.*, 2000)

No passo para frente (*forward*) encontram-se os seguintes sub-passos (BRAGA *et. at.*, 2000):

1. A entrada é apresentada à primeira camada da rede, a camada C^0 ;

2. Para a camada C^i a partir da camada de entrada, após os neurônios da camada C^i ($i > 0$) calcularem seus sinais de saída, estes servem como entrada para a definição das saídas produzidas pelos neurônios da camada C^{i+1} ;
3. As saídas produzidas pelos neurônios da última camada são comparadas às saídas desejadas.

A fase *backward* envolve as seguintes etapas (BRAGA *et al.*, 2000):

1. A partir da última camada, até chegar na camada de entrada:
 - 1.1 Os neurônios de camada atual ajustam seus pesos de forma a reduzir os erros nas respostas desejadas dos padrões;
 - 1.2 O erro de um neurônio das camadas intermediárias é calculado utilizando os erros dos neurônios da camada seguinte conectados a ele, ajustados pelos pesos das conexões entre eles.

O algoritmo retropropagação do erro, que faz uso destas duas fases, é apresentado da seguinte maneira:

1. Iniciar os pesos.
2. Existem vários métodos para que o treinamento da rede seja encerrado. Entre os critérios de parada mais utilizados estão:
 - Repetir até a realização de um dado número de épocas (iterações);
 - Repetir até que a diferença entre os erros de duas iterações consecutivas seja próxima de zero ou ficar abaixo de uma constante, ϵ ;
 - encerrar o treinamento quando a porcentagem de classificações corretas estiver acima de uma constante (mais indicados para saídas binárias).
- 2.1 Para cada padrão de treinamento X :
 - 2.1.1 Definir saída da rede através da fase *forward*;
 - 2.1.2 Comparar saídas produzidas com saídas desejadas;
 - 2.1.3 Atualizar pesos dos neurônios através da fase *backward*.

O algoritmo retropropagação do erro é baseado na regra delta proposto por Windrow e Hoff (1960), sendo por isto também chamada de regra delta generalizada. Este algoritmo propõe uma forma de definir o erro dos neurônios das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente.

A derivação da regra delta generalizada é semelhante à derivação da regra delta. A função custo a ser minimizada é uma função de erro, definida pela soma dos erros quadráticos e representada por

$$E = \frac{1}{2} \sum_p \sum_{i=1}^k (d_i^p - y_i^p)^2, \quad (32)$$

onde E é a medida de erro total, p é o número de padrões, k é o número de unidades de saída, d_i é a i -ésima saída desejada e y_i é a i -ésima saída gerada pela rede. Esta equação define o erro total cometido pela rede, ou a quantidade em que, para todos os padrões p de um dado conjunto, as saídas geradas pela rede diferem das saídas desejadas.

A regra delta generalizada requer que as funções de ativação utilizadas pelos neurônios sejam contínuas, diferenciáveis e, geralmente, não-decrescentes da entrada total recebida pelo neurônio. A EQUAÇÃO (33) ilustra o cálculo do valor de ativação, tal que

$$y_j^p = f_j(\text{rede}_j^p), \quad (33)$$

onde

$$rede_j^p = \sum_{i=1}^n x_i^p w_{ji} . \quad (34)$$

A constante n representa o número de conexões de entrada do neurônio j para camada seguinte, e w_{ji} são os pesos entre estas conexões.

O algoritmo retropropagação do erro apresenta uma série de dificuldades ou deficiências que desestimula uma maior disseminação do seu uso. O principal problema diz respeito à lentidão do algoritmo para superfícies mais complexas. Não é raro o algoritmo convergir para mínimos locais. Os mínimos locais são pontos na superfície de erro que apresentam uma solução estável, embora não sejam a saída correta. Desde que o algoritmo de retropropagação do erro foi popularizado algumas pesquisas buscam por técnicas tanto para acelerar o algoritmo quanto para reduzir a incidência de mínimos locais. Dentro destas técnicas, destaca-se o algoritmo de Levenberg-Marquardt (HAGAN e MENHAJ, 1994).

O algoritmo de Levenberg-Marquardt é eficiente quando se trata de redes que não possuem mais do que algumas centenas de conexões a serem ajustadas (HAGAN e MENHAJ, 1994). Ele trabalha de forma a evitar mal-condicionamento de inversão de matrizes. A seguir são descritos os métodos de treinamento: método Levenberg-Marquardt, método Bayesiano com regularização e método *quase*-Newton.

2.6.3.7 Método Levenberg-Marquardt (LM)

O treinamento pelo método LM faz uso de uma função que atualiza os pesos e valores dos limiares (*bias*) de acordo com a otimização LM. Frequentemente é considerado como o mais rápido dos algoritmos de treinamento retropropagação do erro, porém requer maior alocação de memória do que os outros algoritmos.

De acordo com Lera e Pinzolas (2002), as características principais do algoritmo LM são as seguintes:

No algoritmo LM, as mudanças (Δ) nos pesos (\vec{w}) são obtidas solucionando,

$$\alpha \Delta = -\frac{1}{2} \nabla E, \quad (35)$$

onde E é o erro médio quadrático da rede tal que,

$$E = \frac{1}{N} \sum_{k=1}^N [\vec{y}(x_k) - \vec{d}_k]^2, \quad (36)$$

onde N é o número de exemplos, $\vec{y}(x_k)$ é a saída da rede correspondente ao exemplo x_k , e \vec{d}_k é a saída desejada para aquele exemplo.

Os elementos da matriz α são dados por:

$$\alpha_{ij} = (1 + \lambda \delta_{ij}) \sum_{r=1}^p \sum_{k=1}^N \left[\frac{\partial y_r(x_k)}{\partial w_i} \frac{\partial y_r(x_k)}{\partial w_j} \right], \quad (37)$$

onde p é o número de saídas da rede. Começando com pesos iniciais aleatórios, ambos α e ∇E são calculados resolvendo a EQUAÇÃO 35. A correção para os valores dos pesos é obtida por $(\vec{w}' = \vec{w} + \Delta)$, conhecido como época de aprendizado LM. Cada iteração com essas épocas reduz o erro até encontrar um mínimo. A variável λ na EQUAÇÃO 37 é o parâmetro que é ajustado a cada época de acordo com a evolução do erro. Detalhes de equacionamento do algoritmo LM podem ser encontrados, por exemplo, em Hagan e Menhaj (1994).

2.6.3.8 Método Bayesiano com regularização

O método Bayesiano com regularizações é uma função que atualiza os pesos e valores dos lineares de acordo com a otimização LM descritas nas EQUAÇÕES 35, 36 e 37. Tipicamente os algoritmos de treinamento têm como objetivo reduzir a soma dos erros quadrados, entretanto a regularização adiciona mais um termo, ela minimiza a combinação dos erros quadráticos e os pesos, para então produzir uma RNA generalizada e com respostas mais suaves (MACKAY, 1992; FORESSE e HAGAN, 1997).

A função a ser minimizada neste caso é descrita pela seguinte equação (FORESSE e HAGAN, 1997):

$$F = (\lambda(SSE) + \delta(SSW)), \quad (38)$$

onde λ e δ são os parâmetros ajustáveis no contexto do método Bayesiano de regularização; SSE é o somatório dos erros quadráticos e SSW, é o somatório dos pesos quadráticos. A solução e atualização dos dois parâmetros ajustados são realizadas aplicando a lei de Bayes (ver, por exemplo, MACKAY, 1992).

2.6.3.9 Método quase-Newton

O método quase-Newton é uma função que atualiza os pesos e valores de limiar (*bias*). Utiliza informação de segunda ordem (curvatura) acerca da superfície de erro sem a necessidade de se usar a matriz Hessiana gerando uma aproximação para a matriz Hessiana inversa (HAYKIN, 1999). Os algoritmos de retropropagação do erro que utilizam esta técnica recebem a sigla “BFGS” em homenagem aos trabalhos de Fletcher e Powell (1963), Goldfarb (1970) e Shanno (1970).

De acordo com o método quase-Newton a atualização dos pesos é dada por (ver, por exemplo, TAN *et al.*, 2009):

$$w_{k+1} = w_k + \alpha_k d_k, \quad (39)$$

onde d_k e α_k são as direções de busca e o tamanho do passo na iteração k e d_k é definido como:

$$d_k = -H_k g_k, \quad (40)$$

onde H_k é a matriz inversa atual aproximada Hessiana e $g_k = \nabla f(w_k)$ é o vetor gradiente atual.

3 MATERIAL E MÉTODOS

3.1 RECURSOS UTILIZADOS, COOPERAÇÃO E SUPORTE

A pesquisa foi desenvolvida no LAGE (Laboratório de Geodésia Espacial), com o apoio de bolsa de doutorado do CNPq (Conselho Nacional de Desenvolvimento) e período sanduíche no Instituto de Geodésia da Universidade de Karlsruhe na Alemanha pelo projeto PROBRAL (CAPES/DAAD³) (Brasil/Alemanha) com bolsa da CAPES.

Para a parte de modelagem computacional foi utilizado um computador pessoal (*notebook*). Com o sistema operacional Windows Vista™ Basic. Utilizou-se o *software Matlab 7.0* para o desenvolvimento das metodologias, o *software AutoCad 2005* para manipulação de dados vetoriais e o *software Spring 4.3.3* para organizar e visualizar os dados temporais, tabelas e simulações.

Foram desenvolvidos quatro *softwares* sem registro de patente intitulados:

- *Shoreline prediction using linear regression* (2007): este representa o primeiro algoritmo construído para ser executado em *Matlab*, onde a idéia inicial era apenas aplicar a regressão linear nos dados e assim verificar o comportamento dos mesmos. Foi realizado durante o período da elaboração do seminário II, no programa de pós-graduação em Ciências Geodésicas.

- *Shoreline prediction using linear regression II* (2008): para a elaboração da qualificação da tese, uma nova versão atualizada, do primeiro programa foi desenvolvida. Onde o objetivo principal era continuar com o modelo de tendência usando os princípios da regressão linear. Diferencia-se do primeiro apenas na manipulação dos dados de entrada.

³ CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
DAAD – *Deutscher Akademischer Austausch Dienst*

- *Shoreline prediction using robust parameter estimation* (2009): no período de doutorado sanduíche pensou-se em testar outro modelo de tendência, sendo assim uma nova metodologia foi elaborada e adequada como solução utilizando os princípios da estimativa robusta.

- *Neural network shoreline prediction* (2009): com a idéia de aplicar as redes neurais artificiais também no período sanduíche na Alemanha, fez-se uso da *toolbox* de Redes Neurais do *software Matlab 7.0*, para adequar os dados de entrada para este novo conjunto de testes e metodologia.

3.2 MATERIAL

A primeira etapa para predição da linha de costa exigiu esforços para resgatar e organizar os dados temporais em um ambiente chamado de Sistemas de Informações Geográficas (SIG) Costeiro de Matinhos. As linhas de costa temporais foram colocadas em camadas, escolheu-se o *software Spring 4.3.3* (CÂMARA *et al.*, 1996) para organizar os dados temporais. Ele é fornecido pelo INPE (Instituto Nacional de Pesquisas Espaciais), de forma gratuita, e atua como uma ferramenta importante para armazenamento, recuperação e visualização dos dados cartográficos.

Tomou-se o cuidado em transformar todos os dados para um mesmo sistema geodésico de referência. Por exemplo, os dados obtidos da monorestituição digital estavam no sistema SAD-69, e ao serem importados para o *Spring* foram transformados para o mesmo sistema de referência utilizado nos dados vetoriais obtidos por GPS, no caso, o WGS-84 com coordenadas UTM. Foi escolhido o WGS-84 como sistema geodésico de referência, pois este é o sistema utilizado pelo GPS e pelas cartas náuticas fornecidas pela DHN (Diretoria de Hidrografia e Navegação) no Brasil.

A área de estudo refere-se a uma região costeira do litoral paranaense de aproximadamente 6 km de linha de costa onde estão localizados os balneários do município de Matinhos, estado do Paraná, chamados de Caiobá e Matinhos (FIGURA 39).

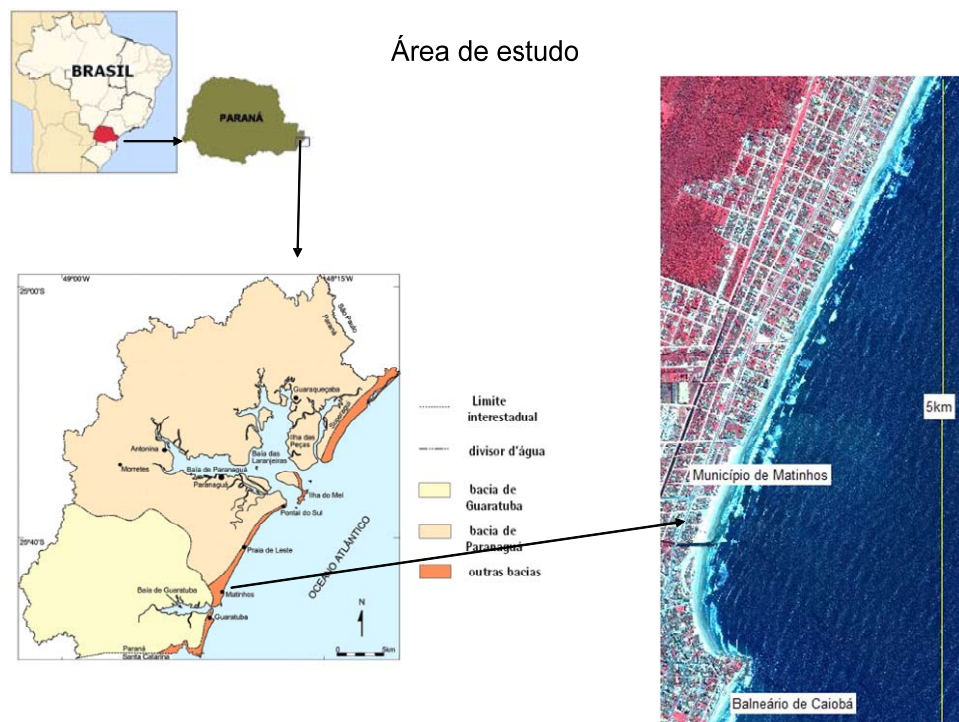


FIGURA 39 - LOCAL DE ESTUDO (LITORAL PARANAENSE: CAIOBÁ E MATINHOS)

As linhas de costa temporais são os resultados de alguns trabalhos e projetos de pesquisas. Entre eles o projeto DIAMAT (2000). Nele encontram-se as linhas de costa obtidas pela monorestituição digital e dados referentes ao posicionamento relativo cinemático com receptores GPS, assim como uma imagem de satélite de alta resolução IKONOS II. Outras informações adicionais, como fotografias do local, compuseram a base cadastral do sistema.

Nas FIGURAS 40 (a) e 40 (b) apresentam-se, respectivamente, duas imagens de fotografias áreas utilizadas neste projeto retiradas de Tedesco *et al.* (2000). É possível analisar na foto do ano de 1954, apresentada na FIGURA 40 (a) as principais dificuldades encontradas que aparecem normalmente quando se trabalha com dados temporais antigos. Entre elas destaca-se a dificuldade de localizar pontos de controle fotogramétrico, pois o cenário composto naquela época, na maior parte da imagem apenas, apresenta feições de vegetação e mar.

Na FIGURA 40 (b), do ano de 1997, a orla está praticamente ocupada com várias construções e obras urbanas, demonstrando uma expansão na urbanização de Matinhos. Em relação ao processo de extração de linha de costa espera-se naturalmente uma precisão maior no processo utilizando a foto do ano de 1997 em comparação com a de 1954, por exemplo.



(a) 1954



(b) 1997

FIGURA 40 – FOTO AÉREA VERTICAL DE MATINHOS PARA OS ANOS 1954 E 1997
FONTE: TEDESCO *et al.* (2000)

3.3.1 Levantamento da linha de costa

O levantamento geodésico de linha de costa em Matinhos vem sendo efetuado pelo método de posicionamento relativo cinemático (item 2.4.5). A estação base é instalada no ponto denominado “PEDRA”, com coordenadas geodésicas conhecidas ($25^{\circ}49'05,7799''\text{S}$, $48^{\circ}31'49,1364''\text{W}$), referidas ao sistema geodésico WGS-84, localizada na “pedra de Matinhos”, conforme mostrado na FIGURA 41.



FIGURA 41 – ESTAÇÃO BASE INSTALADA NO MARCO GEODÉSICO “PEDRA” EM MATINHOS

O número de pessoas necessárias para efetuar este mapeamento é, de no mínimo, três. Uma para instalar e cuidar do equipamento que fica na estação base, no caso o marco geodésico PEDRA, e duas pessoas com receptores GPS móveis, para

realizar o caminhamento sobre a linha de costa. Sendo assim, o levantamento cinemático é realizado por essas duas pessoas, cada uma partindo de uma extremidade da linha de costa em estudo, que se encontram no decorrer do trecho. A extremidade mais ao sul está localizada na praia brava de Caiobá, onde o levantamento inicia-se próximo à Rua Londrina, praticamente em frente do Edifício *Pipeline*. No trecho mais ao norte o levantamento cinemático inicia-se em frente do Edifício *Flórida Terrace*, próximo à Rua das Orquídeas. Na FIGURA 42 apresentam-se: a representação vetorial da linha de costa efetuada pelo rastreo de GPS, sobre uma imagem de satélite (IKONOS); a localização aproximada do início da área de estudo ao norte e sul de Matinhos e o local onde se encontra materializado o marco geodésico PEDRA.

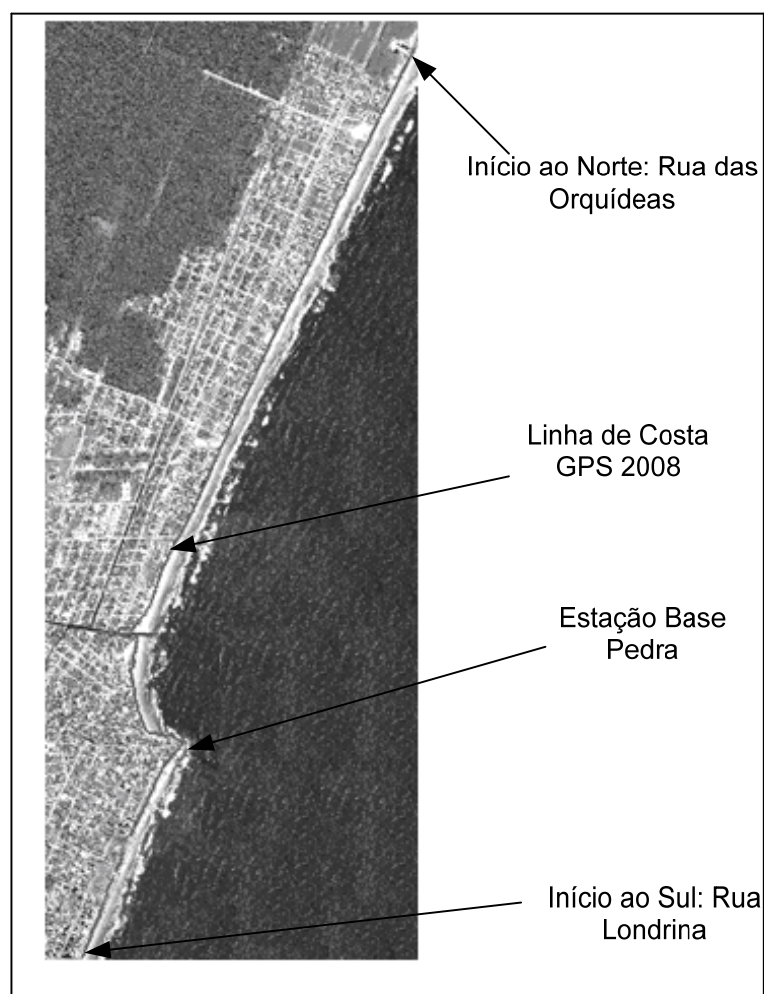


FIGURA 42 – LOCALIZAÇÃO DA ESTAÇÃO BASE E LIMITES DO MAPEAMENTO

3.3.2 Linhas de costa temporais obtidas por monorestituição e GPS

Na FIGURA 43 (a) são representadas as linhas de costa temporais dos anos de 1954, 1963, 1980, 1991 e 1997 obtidas pela monorestituição.

As linhas de costa obtidas por posicionamentos relativos cinemáticos com o uso de receptores GPS, para os anos de 2001, 2002, 2005 e 2008 são representadas na FIGURA 43 (b).

Destaca-se que, para cada linha de costa temporal, existe uma categoria associada. Nela são apresentadas informações referentes à obtenção da respectiva linha.




FIGURA 43 - LINHAS DE COSTA TEMPORAIS: (a) FOTOGAMETRIA (b) GPS

3.4 MÉTODOS DE TENDÊNCIA PARA LINHA DE COSTA

No decorrer da pesquisa foram realizados três experimentos para verificar a tendência da linha de costa: o primeiro utilizando regressão linear simples (seção 2.6.1); o segundo com o modelo de estimativa robusta (seção 2.6.2) e um terceiro experimento utilizando redes neurais artificiais, a qual está descrita na seção 2.6.3.

A estrutura do algoritmo construído para realizar a predição de linha de costa e o experimento proposto segue os passos simplificados no diagrama de blocos da FIGURA 44, que serão detalhados na seqüência, através de quatro etapas.

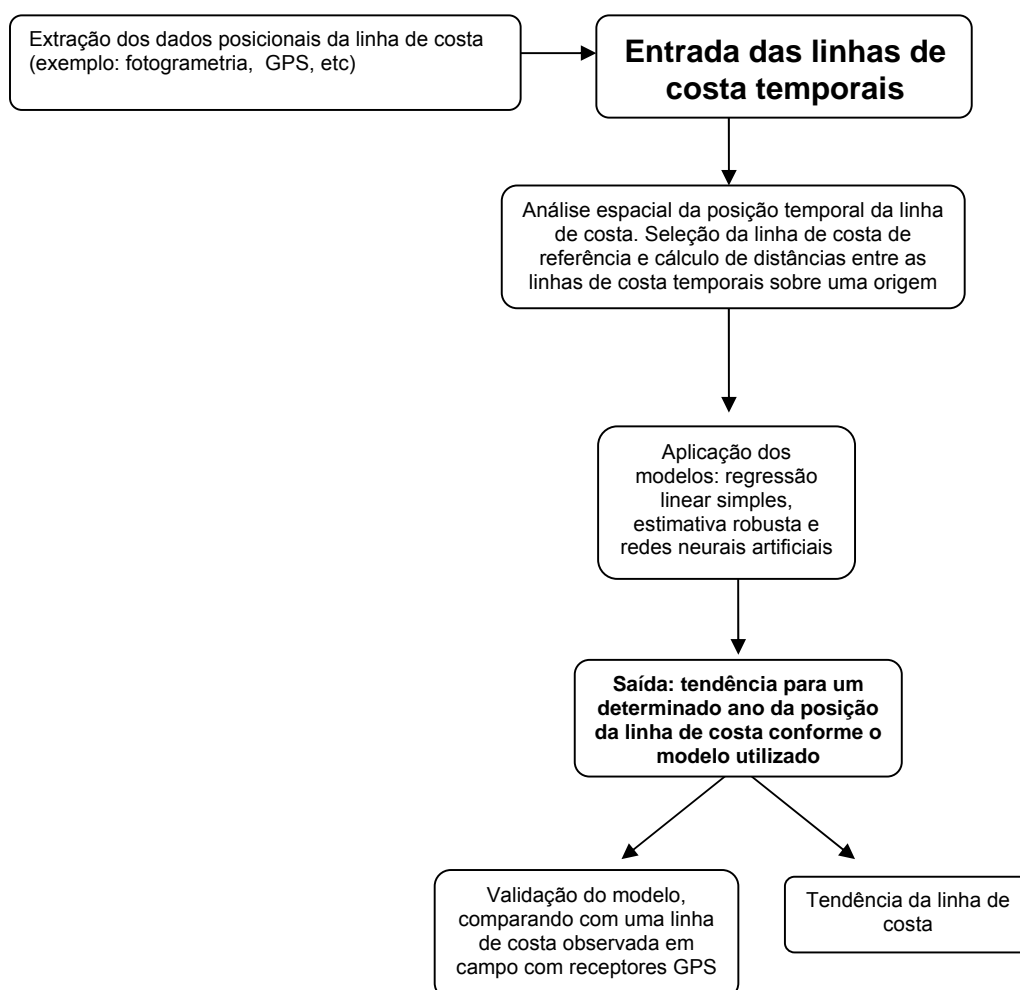


FIGURA 44– DIAGRAMA DE BLOCOS PARA O PROCESSO DE TENDÊNCIA DA LINHA DE COSTA

1) **Entrada das linhas de costa temporais:** para a modelagem de tendência, inicialmente, todas as informações temporais de linha de costa devem ser inseridas no mesmo sistema geodésico de referência, com coordenadas planas no sistema UTM (fuso 22), o qual facilita as medidas de distâncias. A FIGURA 45 apresenta um esquema mostrando um exemplo de linha de costa temporal conforme um determinado ano de obtenção representado pela letra t , variando de t_1, t_2, \dots, t_n , apoiado por um sistema de coordenadas UTM, onde o eixo x é representado por E e o eixo y por N.




FIGURA 45 - LINHAS DE COSTA TEMPORAIS

2) **Análise espacial da posição temporal da linha de costa:** nesta etapa, uma das linhas de costa temporal, de determinado ano, deve ser selecionada, com o objetivo de servir de referência para analisar a movimentação da posição linha de costa no decorrer do tempo. De preferência, deve-se escolher uma das linhas de costa que compreenda os limites de extensão da faixa costeira em estudo. Sendo assim o critério convencionado foi utilizar a linha de costa mais antiga obtida por GPS. Após realizado isso, são traçadas seções transversais em relação à linha de costa nomeada como

referência. Nesta etapa seleciona-se uma distância entre estas seções transversais, conforme esquema indicado na FIGURA 46.

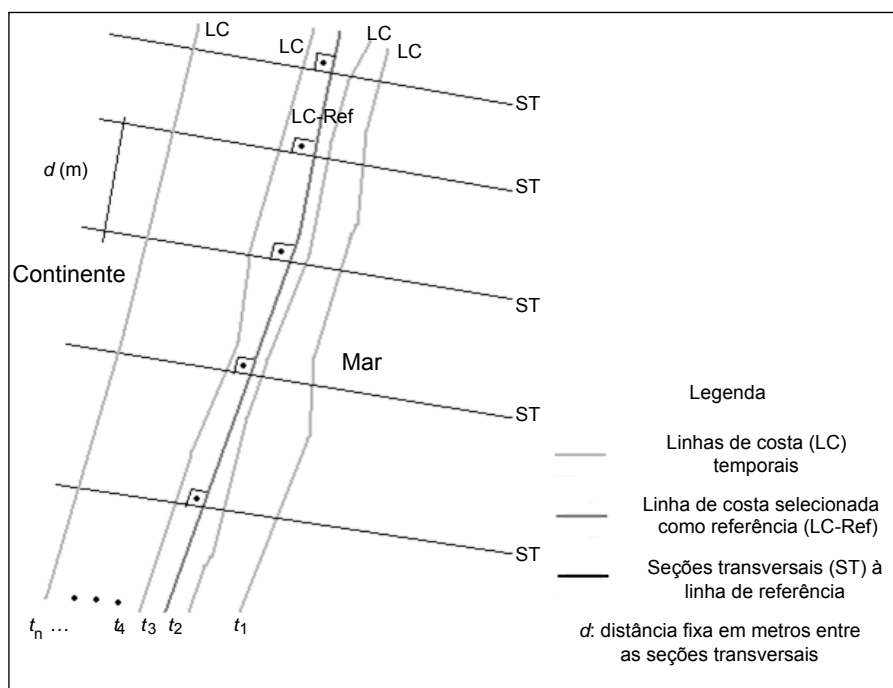


FIGURA 46 - SEÇÕES TRANSVERSAIS À LINHA DE REFERÊNCIA E DISTÂNCIAS PRÉ-SELECIONADAS ENTRE AS LINHAS TRAÇADAS

O próximo passo é coletar as coordenadas dos pontos (a_1, a_2, \dots, a_n ; b_1, b_2, \dots, b_n ; n_1, n_2, \dots, n_n) que interceptam as linhas de costa temporais com as seções transversais à linha de referência (FIGURA 47).




FIGURA 47 - PONTOS QUE INTERCEPTAM AS RETAS TRAÇADAS

Em seguida calculam-se as distâncias em metros dos deslocamentos dos pontos coletados (anos *versus* deslocamento) em relação a uma origem arbitrária (fixa), para

todas as seções transversais à linha de referência (FIGURA 48). Esta origem arbitrária poderia ser, por exemplo, o cruzamento entre a seção transversal com a linha de costa de referência, mas para evitar valores negativos ela é transladada e fixada em direção ao oceano.




FIGURA 48 – COLETA E ARMAZENAMENTO DOS DADOS EM TABELAS

A próxima etapa, é construir o diagrama de dispersão dos dados (FIGURA 49), para cada seção transversal.




FIGURA 49 - DIAGRAMAS DE DISPERSÃO, ANO VERSUS DISTÂNCIA EM METROS
No caso da FIGURA 49:

Y = variável dependente = deslocamento (m) = $d(m)$

X = variável explanatória = ano

3) **Aplicação dos diferentes modelos de predição:** regressão linear, estimativa robusta e redes neurais artificiais.

4) **Saída:** predição para determinado ano; isto é, predição de um passo à frente de t_n tal que

$$t_{n+1}. \quad (41)$$

Através da EQUAÇÃO 41 o usuário escolhe um ano para predição da linha de costa. Para avaliar a qualidade da predição dos modelos seleciona-se uma linha de costa para controle, que não participou como dado de entrada nestes modelos. Desta forma, é possível avaliar o desempenho dos modelos de tendência, comparando os dados preditos com os dados observados (de controle).

Feito isto, se obtém os pontos da tendência da linha de costa. Posteriormente, estes pontos são ligados (por retas), formando assim a linha de costa predita (FIGURA 50).




FIGURA 50- LINHA DE COSTA PREDITA PARA O ANO t_n+1

3.4.1 Experimento prático para aplicação dos modelos de tendência

A seguir são apresentadas as etapas realizadas na parte prática.

a) Determinação da linha de costa de referência

Todos os dados históricos são colocados em camadas. Feito isto, é escolhida uma das linhas de costa para servir de referência para serem traçadas seções transversais. No caso, a primeira linha temporal obtida por GPS (2001) foi selecionada como referência, visto que esta compreendia os limites de extensão da faixa costeira em estudo. A partir dela foram traçadas seções transversais com uma distância de 100 m. Posteriormente, outro teste, com a distância fixa de 25 m foi efetuado. A FIGURA 51 mostra um esquema com a linha de referência escolhida juntamente com as seções transversais à mesma.

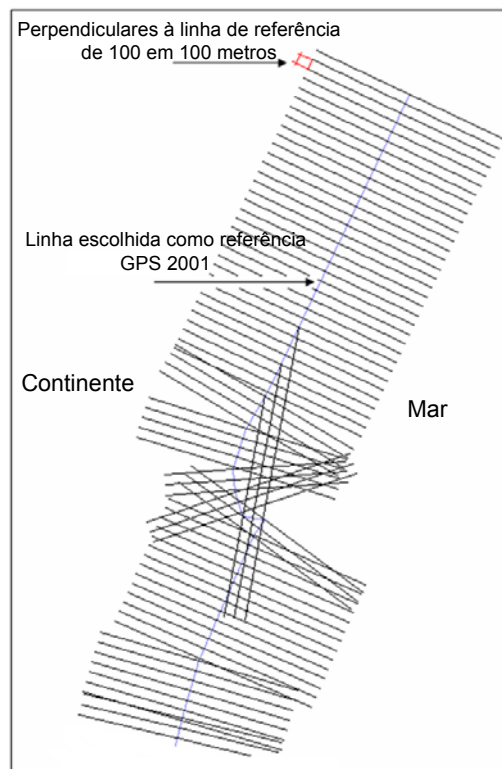


FIGURA 51- LINHA DE REFERÊNCIA ESCOLHIDA E SEÇÕES TRANSVERSAIS

b) Coleta de coordenadas e geração de tabelas

As coordenadas dos pontos de interseção das linhas temporais com as seções transversais (FIGURA 52) são armazenadas em tabelas.




FIGURA 52 - PONTOS DE INTERSECÇÃO ENTRE AS LINHAS DE COSTA TEMPORAIS E SEÇÕES TRANSVERSAIS

No QUADRO 3 mostra-se um exemplo de como os dados foram organizados.

Seções transversais	Origem (O)		1954		1963		1980	
	E (m)	N (m)	E (m)	N (m)	E (m)	N (m)	E (m)	N (m)
1	749967,78	7145812,24	0,00	0,00	749061,35	7146243,47	0,00	0,00
2	749924,82	7145721,93	0,00	0,00	734015,75	7146154,43	0,00	0,00
3	719881,90	7145631,63	0,00	0,00	748970,28	7146065,32	0,00	0,00
4	749838,90	7145541,33	0,00	0,00	748925,27	7145975,99	0,00	0,00
...

QUADRO 3 - COORDENADAS UTM (WGS-84) NOS DISTINTOS ANOS DOS PONTOS DE INTERSECÇÃO

Com as coordenadas dos pontos de interseção, são calculadas as distâncias em metros, a partir de uma origem arbitrária para cada ponto, conforme indicado no QUADRO 4.

Seções transversais	Distância (O - 1954) (m)	Distância (O - 1954) (m)	Distância (O - 1954) (m)
1	0,00	1003,78	0,00
2	0,00	1006,71	0,00
3	0,00	1009,48	0,00
4	0,00	1011,75	0,00
...

QUADRO 4 - DISTÂNCIA DA ORIGEM AO PONTO DE INTERSEÇÃO

As linhas de costa obtidas pela fotogrametria, nem sempre começam e terminam no mesmo local, existem algumas extensões sem informações devido ao recobrimento aéreo (tomada da foto aérea) no local de estudo. As que são obtidas por GPS, apresentam uma descontinuidade apenas no contorno da “pedra” de Matinhos, pois não é possível fazer o caminhando a pé em parte deste local. Quando não existe informação da posição de determinada linha temporal na seção transversal em estudo, convencionou-se o valor zero, nas tabelas, indicando a ausência da distância entre a origem e ano.

Na prática, existem 57 linhas transversais que estão numeradas na FIGURA 53 contendo as informações apresentadas no QUADRO 5: número de seções transversais; quantidade de dados temporais no conjunto e graus de liberdade em relação ao modelo matemático linear, ou seja, a diferença entre as variáveis e o número de equações independentes.

Seções transversais	Dados temporais contidos no conjunto	Graus de liberdade
10	1963 2001 2002 2005	2
15	1963 1980 2001 2002 2005	3
10	1954 1963 1980 2001 2002 2005	4
7	1954 1963 1980 1991 2001 2002 2005	5
9	1954 1963 1980 1991 1997 2001 2002 2005	6
1	1963 1980 1997 2001 2002 2005	4
5	1963 1980 1997 2001 2002	3
Total = 57		

QUADRO 5 – DIVISÃO DOS DADOS CONFORME O NÚMERO DE DADOS TEMPORAIS

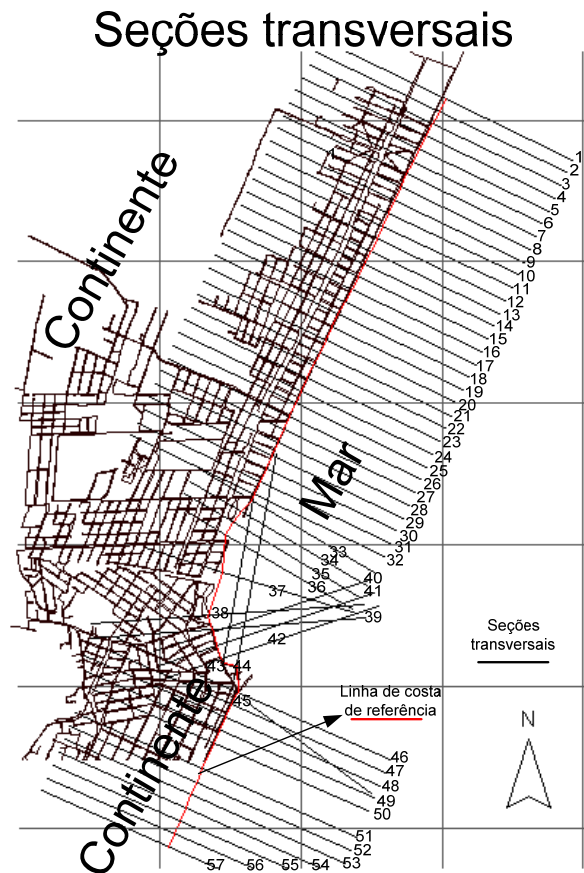


FIGURA 53– NUMERAÇÃO DAS SEÇÕES TRANSVERSAIS (1 à 57)

c) Modelos de tendência: regressão linear e estimativa robusta

Inicialmente, é necessário preparar os dados para serem aplicados aos modelos de regressão linear e de estimativa robusta, abrangendo quatro etapas:

- (1) a matriz dos pesos;
- (2) a matriz A ;
- (3) o vetor das observações;
- (4) o vetor de controle.

(1) A matriz dos pesos

A matriz dos pesos pode controlar o grau de confiança para os dados em um modelo de tendência. A elaboração da matriz dos pesos é apresentada conforme a EQUAÇÃO 23, onde três testes foram propostos e realizados.

Teste da matriz de peso 1

Para os mapeamentos efetuados com GPS para os anos de 2001, 2002, 2005 e 2008 após o re-processamento dos dados brutos obtidos da linha de costa com o método relativo cinemático (2.4.5) filtraram-se os dados, selecionando aqueles em que a componente das incertezas planimétricas fossem menores que 20 cm, valor este adotado em função do conjunto de dados processados, visto que apenas poucos dados ultrapassavam esse limiar imposto.

Para os dados da monorestituição digital considerou-se os anos de 1954, 1963, 1980, 1991 e 1997 como sendo de qualidades incertas. Estima-se que o erro posicional envolvido na extração da linha de costa a partir de fotografias aéreas verticais é em torno de 8 m (CROWELL *et al.* 1991). Como não foi possível estimar seguramente a qualidade dos dados da monorestituição convencionou-se como sendo duas vezes o erro reportado por Crowell *et al.*(1991).

Pesos de 16 m foram assumidos para os dados fotogramétricos e 20 cm para os dados de GPS. A montagem da matriz peso, onde os pesos são considerados como sendo o inverso da variância é configurada da seguinte forma:

$$W_1 = \begin{bmatrix} \left(\frac{1}{16}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \left(\frac{1}{16}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \left(\frac{1}{16}\right)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \left(\frac{1}{16}\right)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \left(\frac{1}{16}\right)^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 \end{bmatrix}$$

Teste da matriz de peso 2

Considerar o peso dos dados da Fotogrametria como sendo duas vezes o erro reportado na literatura por Crowell *et al.* (1991), foi efetuado no teste da matriz de peso 1. A extração da linha de costa depende de alguns fatores como, por exemplo, a escala da fotografia e a qualidade das orientações das fotos e a fotointerpretação para restituir a linha de costa.

Não foi possível recuperar o material com que foram extraídas as linhas de costa temporais, mas conversando com a pessoa responsável⁴ por essa extração na época em que foi efetuada, chegaram-se as seguintes informações:

- As fotografias aéreas eram para mapeamentos cadastrais, cuja escala era de cerca de 1:8000 para mapear na escala 1:2000.

⁴ O responsável por extrair e executar todos os processos referentes a monorestituição digital de linha de costa que foram realizadas no projeto DIAMAT (2000) foi Juilson José Jubanski, aluno de iniciação científica na época.

- As precisões encontradas, sem levar em conta a fotointerpretação, foram aproximadamente: 1954: 10 m; 1963: 10 m; 1980: 4 m; 1991: 2 m; 1997: 1,5 m.

A partir destas informações, montou-se o teste para a matriz de peso 2, que é representada da seguinte maneira:

$$W_2 = \begin{bmatrix} \left(\frac{1}{10}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \left(\frac{1}{10}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \left(\frac{1}{4}\right)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \left(\frac{1}{2}\right)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \left(\frac{1}{1,5}\right)^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{0,20}\right)^2 \end{bmatrix}$$

Teste da matriz de peso 3

Nos dois testes anteriores levaram-se em conta apenas considerações a respeito dos pesos dos dados obtidos pela fotogrametria. Porém, é necessário considerar que em um levantamento relativo cinemático também podem ocorrer erros de interpretação na hora do caminhamento sobre a linha de costa. Desta forma, o teste 3 considera os pesos da fotogrametria iguais aos pesos do teste 2, e os pesos dos dados obtidos por GPS foram considerados agora como sendo iguais a 1 metro.

A seguir a matriz de peso 3:

$$W_3 = \begin{bmatrix} \left(\frac{1}{10}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \left(\frac{1}{10}\right)^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \left(\frac{1}{4}\right)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \left(\frac{1}{2}\right)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \left(\frac{1}{1,5}\right)^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{1}\right)^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{1}\right)^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \left(\frac{1}{1}\right)^2 \end{bmatrix}$$

(2) a matriz A

A informação temporal, anos, é usada para construir a matriz “design” A. A segunda coluna é representada por “1”, tal que

$$A = \begin{bmatrix} 1954 & 1 \\ 1963 & 1 \\ 1980 & 1 \\ 1991 & 1 \\ 1997 & 1 \\ 2001 & 1 \\ 2002 & 1 \\ 2005 & 1 \end{bmatrix}$$

(3) o vetor das observações

Os elementos de observação y na EQUAÇÃO (14) são formados pelas distâncias em metros da origem arbitrária de referência até a linha de costa temporal.

(4) o vetor de controle

O vetor com a posição da linha de costa relacionada com a época obtida por GPS 2008 foi utilizado como vetor de controle, conforme análises descritas no próximo capítulo.

d) Aplicação de restrição condicionada à altitude

A região de estudo é praticamente plana, com altitudes de zero a três metros acima do nível do mar, com exceção a uma parte que divide o balneário de Caiobá e Matinhos, popularmente conhecido como a “pedra” de Matinhos (detalhes na FIGURA 54).

Nessa localidade encontram-se altitudes ortométricas de até 5 m e o caminhamento efetuado por GPS é interrompido devido à falta de acesso a pé para efetuar o mapeamento da linha de costa.

Aplicou-se para este trecho uma regra de restrição condicionada a altitude da seguinte forma: para altitudes acima de 4 m a predição é bloqueada. Na FIGURA 55 apresenta-se uma grade regular com estas altitudes e uma área destacando as altitudes acima de 4 m, que delimita a extensão onde não é possível efetuar o caminhamento com o receptor GPS. Essa regra foi utilizada pressupondo que, o comportamento em áreas rochosas, neste pequeno trecho em função da altitude, deve ser diferenciado das demais áreas sedimentares.



FIGURA 54 - "PEDRA" DE MATINHOS

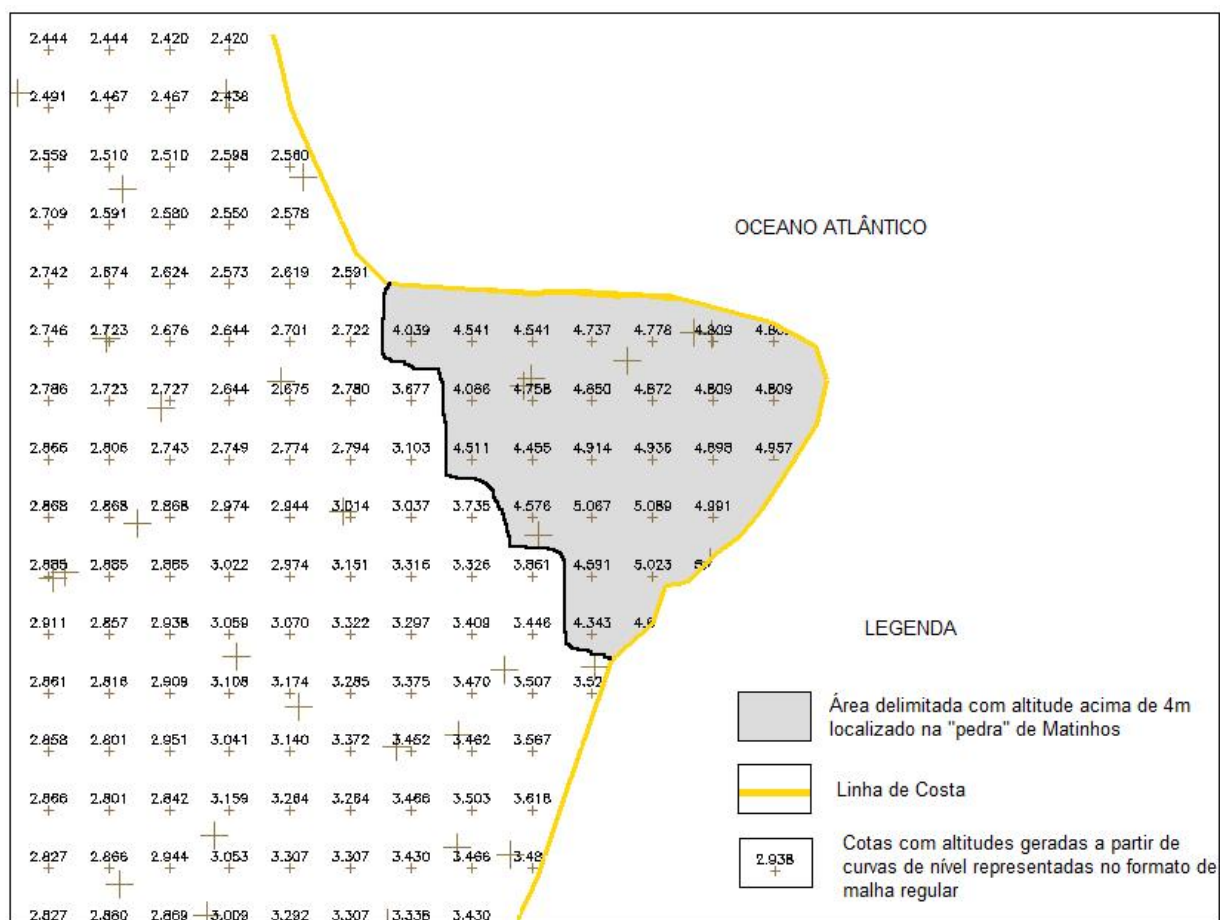


FIGURA 55 - GRADE REGULAR DE ALTITUDES ORTOMÉTRICAS E ÁREA DELIMITADA COM ALTITUDE ACIMA DE 4 m

e) Redes Neurais Artificiais

Os testes utilizando redes neurais artificiais estão divididos em três, todos com a característica de treinamento não-supervisionado. Ou seja, são fornecidas apenas informações para rede sobre as distâncias da linha de costa como sendo os neurônios de entrada. A RNA aprende relações conforme as características destas informações de entrada e descobre qual a saída para passos adiante que seriam as previsões de 2008 e 2055. Os dados de 2008 não participam do treinamento e, assim como na regressão linear, e estimativa robusta, servem como controle para verificar a resposta encontrada pelo modelo preditivo. Destaca-se que nenhum tipo de peso é selecionado para os dados de entrada. A seguir apresentam-se as características dos testes realizados.

As características dos testes realizados são:

Teste 1: RNA – MLP usando Levenberg-Marquardt (LM)

O primeiro teste utiliza a rede neural (RNA) multicamadas *perceptron* (*neural network multilayer perceptron* – (MLP) através do algoritmo de treinamento de Levenberg-Marquardt (LM), de acordo com as características apresentadas no QUADRO 6.

Teste 1 - Arquitetura MLP	
Rede neural	MLP
Método de treinamento	Levenberg-Marquardt (LM)
Número de camadas ocultas	1
Número de neurônios na camada escondida	2,4,5,10
Função de ativação utilizada na camada escondida	tangente hiperbólica
Função de ativação utilizada na camada de saída	linear

QUADRO 6 – TESTE 1 COM RNA – MLP USANDO LM

Teste 2: RNA – MLP usando o método Bayesiano com regularização

No segundo teste com as RNA utilizou-se a mesma arquitetura do teste 1, a MLP, porém com outro algoritmo de treinamento no caso o método Bayesiano com regularização, de acordo com as características descritas no QUADRO 7.

Teste 2 - Arquitetura MLP	
Rede neural	MLP
Método de treinamento	Bayesiano com regularização
Número de camadas ocultas	1
Número de neurônios na camada escondida	2,4,5,10
Função de ativação utilizada na camada escondida	tangente hiperbólica
Função de ativação utilizada na camada de saída	linear

QUADRO 7 - TESTE 2 COM RNA – MLP USANDO BAYESIANO COM REGULARIZAÇÕES

Teste 3: - RNA de Elman usando o método *quase-Newton*

No terceiro teste com as RNA, utilizou-se a arquitetura de Elman com o algoritmo de treinamento método quase-Newton, de acordo com as características descritas no QUADRO 8.

Teste 3 – Elman	
Rede neural	Elman
Método de treinamento	quase-Newton
Número de camadas ocultas	1
Número de neurônios na camada escondida	2,4,5,10
Função de ativação utilizada na camada escondida	tangente hiperbólica
Função de ativação utilizada na camada de saída	linear

QUADRO 8 - TESTE 3 COM RNA – ELMAN USANDO QUASE-NEWTON

3.4.2 Critérios de Avaliação

Nos experimentos realizados, os métodos foram avaliados com base na sua eficácia em modelar os dados temporais obtidos por diferentes fontes. Para avaliar o desempenho dos três métodos de tendência, foram calculados:

- (1) A média aritmética do desvio da linha de costa usada como controle, conforme o levantamento efetuado por GPS em 2008. Isto foi calculado usando:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n (GPS2008_i - Predição2008_i), \quad (42)$$

onde $(GPS2008_i - Predição2008_i)$ é a distância de linha de costa predita em relação à linha de controle na i -ésima seção transversal, e n é o número de seções.

- (2) O desvio padrão, medida mais comum da dispersão estatística, foi obtido pela raiz quadrada da variância da posição da linha de costa estimada pela equação:

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n \left((GPS2008_i - Predi\tilde{c}ao2008_i) - x \right)^2}. \quad (43)$$

- (3) O erro médio quadrático, RMS (*root mean square*) da linha de costa é calculado para avaliar a respectiva eficácia do método. O RMS pode ser escrito como:

$$RMS = \sqrt{\frac{1}{n-1} \sum_{i=1}^n \left(GPS2008_i - Predi\tilde{c}ao2008_i \right)^2}. \quad (44)$$

- (4) O coeficiente de correlação R^2 foi calculado para verificar o ajuste dos dados preditos com a linha de costa de controle usando a seguinte equação (SCHAIBLE e LEE, 1996):

$$R^2 = 1 - \frac{\sum_{i=1}^n (GPS2008_i - Predi\tilde{c}ao_i)^2}{\sum_{i=1}^n (GPS2008_i - médiaGPS2008)^2}. \quad (45)$$

- (5) Finalmente, para verificar o desempenho dos modelos preditivos foi quantificado o erro de percentagem média absoluta (*mean absolute percentage error*) (MAPE), que representa uma estatística da medida de acurácia no ajustamento de dados em séries temporais. O MAPE é utilizado especialmente em previsões, seu resultado usualmente é expressado em termos de percentagem (HAYATI e SHIRVANY, 2007):

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{GPS2008_t - Predição2008_t}{GPS2008_t} \right|. \quad (46)$$

(a) A predição para 2008

Para 2008 foram obtidas três linhas de costa preditas, conforme cada modelo de predição. O ano de 2008 foi selecionado para testar as modelagens em questão, ou seja, é retirada da modelagem a linha temporal de 2008 e posteriormente é efetuada uma predição para 2008 com o objetivo de comparar os resultados entre a linha de costa predita e observada por GPS em 2008.

(b) A predição para 2055

Uma vez testados os modelos de predição para 2008, é efetuado uma predição para 2055, 50 anos depois da última entrada de dados (2005), para verificar as conseqüências e comportamentos dos diferentes modelos.

4 RESULTADOS E DISCUSSÃO

4.1 RESULTADOS PARA TENDÊNCIA DA LINHA DE COSTA PARA O ANO DE 2008

Apresenta-se no QUADRO 9 um resumo contendo as principais configurações dos testes efetuados.

Resumo dos testes efetuados									
Modelagem preditiva	Pesos para os respectivos anos								
	Teste	1954	1963	1980	1991	1997	2001	2002	2005
Regressão linear e estimativa robusta	1	16 m	16 m	16 m	16 m	16 m	0,20 m	0,20 m	0,20 m
	2	10 m	10 m	4 m	2 m	1,5 m	0,20 m	0,20 m	0,20 m
	3	10 m	10 m	4 m	2 m	1,5 m	1 m	1 m	1 m
Redes neurais artificiais	Características principais								
	Teste	Arquitetura	Método de treinamento						
	1	MLP	LM						
	2	MLP	Bayesiano com regularização						
	3	Elman	Quase-Newton						

QUADRO 9 – RESUMO DOS TESTES EFETUADOS

4.1.1 Resultados para os testes utilizando estimativa robusta e regressão linear

Os QUADROS 10, 12 e 14 mostram os resultados para os métodos de predição regressão linear e estimativa robusta, conforme os testes elaborados com diferentes pesos, formulados no capítulo anterior e resumo das características que podem ser encontradas no QUADRO 9. As primeiras colunas destes quadros⁵ (A) se referem às seções transversais, que somam 57. A segunda coluna (B) apresenta o número de iterações realizadas para a melhor solução apresentada pela estimativa robusta. Destaca-se que, quando o número de iterações é igual a 1, significa que a solução encontrada pela estimativa robusta é a mesma encontrada pela regressão linear. Os valores absolutos em metros da diferença entre os valores preditos e os

⁵ Para melhor aproveitamento da página e visualização dos QUADROS optou-se em repetir o conteúdo das quatro primeiras colunas ao lado na mesma página e assim dar continuação dos resultados encontrados conforme as seções transversais de 30 a 57.

valores reais de GPS 2008 (utilizados como controle) para cada seção em estudo são apresentados nas colunas três (C) e quatro (D) de acordo com o modelo de tendência, estimativa robusta e regressão linear respectivamente.

Os valores dos QUADROS 11, 13 e 15 foram calculados utilizando as EQUAÇÕES 42 a 46 seguidos dos valores mínimos e máximos para os dados encontrados nos QUADROS 10, 12 e 14.

Teste para a matriz peso 1							
Seções transversais	Número de iterações para melhor solução da estimativa robusta	Estimativa Robusta (GPS2008-Predição) Valor absoluto (m)	Regressão Linear (GPS2008-Predição) Valor absoluto (m)	(A)	(B)	(C)	(D)
(A)	(B)	(C)	(D)	(A)	(B)	(C)	(D)
1	12	0,85	14,35	30	3	0,12	0,36
2	13	1,36	14,54	31	3	0,69	1,44
3	28	1,01	8,94	32	2	1,18	3,70
4	1	1,31	1,31	33	2	3,01	8,57
5	14	0,90	5,29	34	2	2,15	9,22
6	3	0,93	6,48	35	5	0,30	28,74
7	1	0,29	0,29	36	7	6,00	57,29
8	20	0,47	7,58	37	19	0,36	47,36
9	2	2,13	2,20	38	3	0,36	13,68
10	2	0,45	4,75	39	1	1,57	1,57
11	27	2,24	12,84	40	3	0,07	5,37
12	2	0,68	6,54	41	1	4,21	4,21
13	2	0,81	6,62	42	3	1,46	4,51
14	2	1,58	3,97	43	1	4,77	4,77
15	2	0,23	5,23	44	5	0,01	1,99
16	2	1,76	4,04	45	1	6,73	6,73
17	2	0,23	5,35	46	1	6,21	6,21
18	1	1,61	1,61	47	1	0,73	0,73
19	1	0,79	0,79	48	3	0,28	3,23
20	1	1,60	1,60	49	2	1,97	2,10
21	1	0,78	0,78	50	2	0,28	1,36
22	1	1,24	1,24	51	2	0,68	3,28
23	1	0,32	0,32	52	1	7,63	7,63
24	1	1,29	1,29	53	2	2,36	2,62
25	1	1,24	1,24	54	1	0,27	0,27
26	2	0,06	3,12	55	3	0,04	1,77
27	21	0,50	1,85	56	1	1,20	1,20
28	4	0,45	3,08	57	7	6,20	7,00
29	4	0,70	3,28				

QUADRO 10 – TESTE PARA A MATRIZ DE PESO 1

Crítério	Estimativa Robusta (m)	Regressão Linear (m)
Máximo	7,63	57,29
Mínimo	0,01	0,27
Média Aritmética	1,56	6,45
Desvio Padrão	1,83	10,10
RMS	2,39	11,90
R^2	0,994	0,9844
MAPE	0,14	0,61

QUADRO 11 – AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 1 EM RELAÇÃO À LINHA DE COSTA GPS2008

Teste para a matriz de peso 2							
Seções transversais	Número de iterações para melhor solução da estimativa robusta	Estimativa Robusta (GPS2008-Predição) Valor absoluto (m)	Regressão Linear (GPS2008-Predição) Valor absolute (m)	(A)	(B)	(C)	(D)
(A)	(B)	(C)	(D)	(A)	(B)	(C)	(D)
1	11	1,53	13,48	30	3	0,00	0,16
2	13	0,79	13,66	31	3	0,73	0,88
3	18	1,01	8,64	32	2	1,21	2,62
4	1	1,37	1,37	33	3	2,91	7,20
5	11	0,90	5,12	34	2	2,30	7,84
6	3	1,09	6,10	35	4	0,79	23,85
7	1	0,23	0,23	36	30	9,89	13,31
8	30	0,47	7,30	37	2	11,11	13,79
9	1	1,86	1,86	38	2	0,63	6,74
10	2	0,23	4,35	39	18	1,71	2,12
11	29	2,24	10,90	40	30	1,61	4,81
12	2	0,29	4,74	41	1	5,18	5,18
13	2	0,07	4,89	42	3	1,81	3,69
14	2	2,24	2,42	43	1	4,70	4,70
15	2	0,84	3,71	44	3	0,51	1,98
16	1	2,24	2,24	45	1	7,86	7,86
17	2	0,87	3,77	46	1	7,76	7,76
18	1	0,13	0,13	47	1	0,52	0,52
19	1	1,89	1,89	48	1	0,03	0,03
20	1	2,31	2,31	49	1	0,35	0,35
21	1	0,13	0,13	50	1	0,59	0,59
22	1	1,76	1,76	51	1	1,06	1,06
23	1	0,46	0,46	52	1	7,75	7,75
24	30	1,37	1,61	53	1	0,49	0,49
25	1	0,44	0,44	54	2	0,82	0,84
26	2	0,11	2,50	55	3	0,51	2,51
27	23	0,51	0,62	56	1	1,82	1,82
28	3	0,40	1,80	57	5	6,23	7,72
29	3	0,60	2,00				

QUADRO 12 – TESTE PARA A MATRIZ DE PESO 2

Critério	Estimativa Robusta (m)	Regressão Linear (m)
Máximo	11,11	23,85
Mínimo	0,00	0,03
Média Aritmética	1,84	4,30
Desvio Padrão	2,48	4,62
RMS	3,15	6,31
R^2	0,9989	0,9956
MAPE	0,17	0,41

QUADRO 13 - AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 2 EM RELAÇÃO À LINHA DE COSTA GPS2008

Teste para a matriz peso 3							
Seções transversais	Número de iterações para melhor solução da estimativa robusta	Estimativa Robusta (GPS2008-Predição) Valor absoluto (m)	Regressão Linear (GPS2008-Predição) Valor absoluto (m)	(A)	(B)	(C)	(D)
(A)	(B)	(C)	(D)	(A)	(B)	(C)	(D)
1	1	0,91	0,91	30	4	0,96	2,06
2	1	0,94	0,94	31	4	0,08	1,21
3	4	0,26	4,23	32	4	0,07	1,69
4	1	2,12	2,12	33	1	1,57	1,57
5	5	0,08	2,57	34	5	2,40	2,89
6	2	0,47	0,71	35	2	0,27	5,80
7	1	0,53	0,53	36	1	1,86	1,86
8	4	0,60	3,32	37	8	0,23	5,52
9	1	3,09	3,09	38	1	10,48	10,48
10	1	1,47	1,47	39	5	1,04	3,01
11	21	0,13	2,34	40	1	3,16	3,16
12	1	3,14	3,14	41	2	6,06	6,74
13	1	2,67	2,67	42	1	1,73	1,73
14	1	4,36	4,36	43	1	5,35	5,35
15	1	2,90	2,90	44	3	1,71	2,29
16	27	4,14	5,59	45	1	11,38	11,38
17	3	2,21	3,10	46	1	11,97	11,97
18	3	5,74	6,25	47	1	0,29	0,29
19	4	5,68	6,59	48	22	1,33	3,82
20	5	3,13	5,25	49	30	0,44	1,59
21	29	2,45	4,08	50	3	1,12	2,68
22	6	2,20	3,92	51	2	0,42	1,55
23	4	2,06	3,86	52	18	8,35	8,66
24	4	2,44	2,91	53	20	1,93	4,45
25	14	1,59	3,11	54	18	1,32	2,01
26	1	0,05	0,05	55	12	0,19	3,39
27	30	1,42	3,78	56	4	2,28	2,94
28	30	0,62	2,85	57	2	8,23	8,84
29	30	0,09	2,70				

QUADRO 14 - TESTE PARA A MATRIZ DE PESO 3

Critério	Estimativa Robusta (m)	Regressão Linear (m)
Máximo	11,97	11,97
Mínimo	0,05	0,05
Média Aritmética	2,42	3,57
Desvio Padrão	2,79	2,57
RMS	3,78	4,48
R^2	0,9984	0,9978
MAPE	0,23	0,33

QUADRO 15 - AVALIAÇÕES DO TESTE COM A MATRIZ DE PESO 3 EM RELAÇÃO À LINHA DE COSTA GPS2008

Analisando-se os resultados encontrados dos dois modelos verifica-se:

a) Os resultados das predições dependem da escolha da matriz dos pesos;

b) A estimativa robusta, mesmo mudando os pesos iniciais, chegou a resultados estatísticos parecidos, conforme os valores encontrados (média; desvio padrão; RMS; R^2 ; MAPE) respectivamente para os testes: teste 1 (1,56 m; 1,83 m; 2,39 m; 0,9994; 0,14); teste 2 (1,84 m; 2,48; 3,15 m; 0,9989; 0,17) e teste 3 (2,42 m; 2,79 m; 3,78 m; 0,9984; 0,23).

c) Os melhores resultados utilizando a estimativa robusta encontram-se no teste 1, que foi proposto nomeando os pesos com o valor de 16 m para os dados da Fotogrametria. Ou seja, mesmo não sabendo a precisão de um conjunto de dados a estimativa robusta foi capaz de se adaptar a melhor resposta apresentando como 7,63 m o maior desvio em relação à linha de costa real.

d) A regressão linear apresentou diferenças acima de 8 m quando comparados com os de controle em 10 casos no teste 1, onde o máximo desvio foi de 57,29 m.

e) O melhor resultado encontrado pela regressão linear foi o teste 3. Acredita-se que isto se deve ao fato da escolha dos pesos terem ficado próxima aos pesos reais esperados em relação ao processo de extração de linha de costa.

4.1.2 Resultados dos testes utilizando Redes Neurais Artificiais

Os QUADROS 16, 18 e 20 apresentam os resultados para o método de tendência utilizando redes neurais artificiais. Estes quadros estão divididos em cinco colunas, que representam diferentes processamentos variando os neurônios na camada oculta em 2, 4, 5 e 10, para verificar o comportamento quando este parâmetro é modificado.

Os resultados apresentam a diferença absoluta entre os valores reais de GPS 2008 utilizado como controle e o teste conforme os neurônios na camada oculta, para o conjunto de 57 seções transversais conforme os três testes elaborados quais sejam: MLP com algoritmo de treinamento Levenberg-Marquardt, MLP com algoritmo de treinamento Bayesiano com regularização e a rede parcialmente recorrente de Elman com o algoritmo de treinamento quase-Newton.

Os valores dos QUADROS 17, 19 e 21 foram calculados conforme as equações 42 a 46 seguidos dos valores mínimos e máximos para os dados encontrados nos QUADROS 16, 18 e 20.

Teste 1 RNA MLP – com método Levenberg-Marquardt									
Neurônios na camada oculta									
	2	4	5	10					
Seções	Redes Neurais	Redes Neurais	Redes Neurais	Redes Neurais	Neurônios na camada oculta				
(GPS2008-Predição)	(GPS2008-Predição)	(GPS2008-Predição)	(GPS2008-Predição)	(GPS2008-Predição)	2	4	5	10	
transversais	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)					
1	3,54	3,54	3,88	3,54	30	4,28	4,28	4,28	14,91
2	3,89	3,89	3,59	3,89	31	5,38	5,38	5,38	16,04
3	2,06	2,06	4,77	2,06	32	0,54	0,54	0,54	0,18
4	2,33	2,33	1,75	2,33	33	2,61	2,61	2,61	11,78
5	1,48	1,48	3,11	1,48	34	0,25	0,25	0,25	1,10
6	1,35	1,35	1,98	1,35	35	2,62	2,62	2,62	9,74
7	0,19	0,19	0,18	0,19	36	12,09	12,09	12,09	12,09
8	0,03	0,03	3,13	0,03	37	14,15	14,15	14,15	14,15
9	4,62	4,62	1,50	4,62	38	16,46	16,46	16,46	16,46
10	3,30	3,30	0,04	3,30	39	2,32	2,32	2,32	2,32
11	3,99	4,94	3,99	79,83	40	1,88	1,88	1,88	1,88
12	1,36	0,34	1,36	21,92	41	2,83	2,83	2,83	2,83
13	0,65	0,31	0,65	80,57	42	2,30	2,30	2,30	2,30
14	1,52	0,88	1,52	162,66	43	20,10	4,96	7,42	18,97
15	0,40	1,05	0,40	158,82	44	87,98	1,26	0,56	5,56
16	2,14	0,68	2,14	19,49	45	48,99	11,81	16,38	19,07
17	0,32	1,41	0,32	17,82	46	56,17	11,96	14,48	10,99
18	1,12	0,73	1,12	3,35	47	3,96	3,43	14,25	24,30
19	1,19	1,29	1,19	7,33	48	126,04	1,18	12,25	25,24
20	0,12	0,12	0,12	99,39	49	64,61	3,14	13,16	26,49
21	0,44	0,79	0,44	91,51	50	33,34	2,35	12,95	24,39
22	0,78	1,04	0,78	93,03	51	5,18	3,05	13,40	22,24
23	0,25	0,91	0,25	242,08	52	13,57	13,57	13,57	13,57
24	1,74	1,96	1,74	27,75	53	12,34	12,51	12,34	12,34
25	1,17	1,78	1,17	36,71	54	5,79	4,35	5,79	5,79
26	7,86	7,86	7,86	20,58	55	3,48	2,45	3,48	3,48
27	3,98	3,98	3,98	18,48	56	2,05	1,52	2,05	2,05
28	3,84	3,84	3,84	16,42	57	2,58	3,33	2,58	2,58
29	2,66	2,66	2,66	12,65					

QUADRO 16 – RESULTADOS DO TESTE 1 COM RNA DO TIPO MLP USANDO LM

Resultados para o Teste 1 com RNA do tipo MLP usando Levenberg-Marquardt				
Neurônios na camada oculta	2	4	5	10
Máximo (m)	126,04	16,46	16,46	242,08
Mínimo (m)	0,03	0,03	0,04	0,03
Média Aritmética (m)	11,05	3,69	4,86	28,21
Desvio Padrão (m)	23,37	4,03	5,10	46,46
RMS (m)	25,21	5,36	6,90	53,04
R^2	0,9301	0,9968	0,9947	0,6908
MAPE	0,89	0,33	0,43	2,60

QUADRO 17 – AVALIAÇÃO ESTATÍSTICA PARA O TESTE 1

Teste 2 RNA MLP – utilizando o método Bayesiano com regularização									
Neurônios na camada oculta									
	2	4	5	10					
Seções transversais	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Neurônios na camada oculta				
	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)		2	4	5	10
1	3,52	479,37	1,59	178,22	30	1,42	4,93	1,94	1,99
2	3,87	482,75	1,24	176,67	31	2,51	6,02	3,03	3,08
3	2,08	360,16	7,19	184,03	32	2,21	0,11	2,85	2,8
4	2,32	293,60	2,84	177,93	33	3,09	1,97	4,86	4,81
5	1,49	332,84	6,65	182,67	34	2,00	0,39	2,55	2,51
6	1,33	372,47	3,82	178,6	35	0,20	3,25	0,32	0,37
7	0,18	297,5	4,99	184,13	36	12,06	12,36	12,06	0,51
8	0,01	374,66	5,16	183,26	37	14,18	13,88	14,18	26,16
9	4,60	371,26	0,56	174,85	38	16,50	16,17	16,5	29,06
10	3,28	373,25	1,88	177,28	39	2,36	2,03	2,36	14,98
11	3,33	4,04	3,27	4,26	40	1,92	1,56	1,92	15,58
12	2,01	1,31	1,91	1,09	41	2,87	2,52	2,87	16,62
13	1,3	0,60	1,11	0,38	42	2,34	1,99	2,34	16,07
14	2,17	1,47	2,23	1,25	43	695,61	5,06	9,46	7,41
15	0,24	0,44	0,19	0,66	44	890,76	1,51	2,08	0,58
16	2,79	2,10	2,71	1,87	45	702,49	11,92	18,40	16,37
17	0,32	0,37	0,37	0,59	46	703,88	12,11	16,51	14,47
18	1,75	1,07	2,03	0,85	47	704,79	3,33	16,29	14,24
19	1,81	1,14	1,68	0,92	48	699,73	1,01	14,29	12,24
20	0,71	0,07	0,59	0,15	49	703,53	3,04	15,21	13,15
21	0,17	0,49	0,02	0,71	50	708,18	2,25	15,01	12,94
22	0,20	0,83	0,08	1,05	51	707,97	2,97	15,45	13,39
23	0,36	0,29	0,23	0,51	52	13,70	13,85	14,21	13,78
24	1,16	1,79	1,15	2,01	53	12,72	12,6	12,51	12,52
25	0,56	1,21	0,57	1,44	54	4,57	4,44	4,36	4,37
26	4,75	8,50	5,50	5,55	55	2,67	2,55	2,46	2,47
27	0,65	4,63	1,62	1,65	56	1,73	1,61	1,53	1,54
28	0,73	4,48	1,47	1,52	57	3,11	3,24	3,32	3,31
29	0,12	3,31	0,33	0,37					

QUADRO 18 – RESULTADOS DO TESTE 2 COM RNA DO TIPO MLP USANDO O MÉTODO BAYESIANO COM REGULARIZAÇÃO

Resultados para o Teste 2 com RNA do tipo MLP usando o Método Bayesiano com regularização				
Neurônios na camada oculta	2	4	5	10
Máximo (m)	890,76	482,75	18,40	184,13
Mínimo (m)	0,01	0,07	0,02	0,15
Média Aritmética (m)	121,13	71,27	5,22	38,13
Desvio Padrão (m)	270,27	146,35	5,61	67,73
RMS (m)	288,72	158,72	7,50	75,82
R^2	0,00	0,00	0,9938	0,3680
MAPE	9,56	6,75	0,46	3,57

QUADRO 19 – AVALIAÇÃO ESTATÍSTICA PARA O TESTE COM A RNA 2

Teste 3 RNA de Elman – com método quase-Newton									
Neurônios na camada oculta									
	2	4	5	10					
Seções	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Redes Neurais (GPS2008-Predição)	Neurônios na camada oculta				
Transversais	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)	Valor absoluto (m)		2	4	5	10
1	3,54	6,19	3,46	3,96	30	4,28	4,16	4,16	0,06
2	3,89	6,92	4,19	3,30	31	5,38	5,03	5,03	1,10
3	2,06	0,00	2,73	5,44	32	0,54	0,34	0,34	0,73
4	2,33	2,84	0,08	0,51	33	2,61	4,67	4,67	10,38
5	1,48	1,52	1,25	2,90	34	0,25	3,56	3,56	2,18
6	1,35	3,76	1,00	2,33	35	2,62	16,79	16,79	0,13
7	0,19	1,22	1,55	1,94	36	12,09	10,14	10,14	10,14
8	0,03	0,86	1,90	5,07	37	14,15	0,06	0,06	0,06
9	4,62	1,91	0,86	3,98	38	16,46	7,13	7,12	7,12
10	3,30	2,91	0,14	3,12	39	2,32	1,21	1,20	1,20
11	3,99	0,56	0,61	1,55	40	1,88	0,39	0,39	0,39
12	1,36	0,57	0,53	0,49	41	2,83	1,84	1,84	1,84
13	0,65	0,17	0,12	0,84	42	2,3	2,57	2,56	2,56
14	1,52	1,34	1,38	2,02	43	7,42	2,05	7,66	2,32
15	0,40	1,48	1,53	2,18	44	0,56	1,31	13,89	1,05
16	2,14	5,91	5,87	4,40	45	16,38	6,38	3,24	4,78
17	0,32	0,49	0,54	1,63	46	14,48	10,85	1,18	10,41
18	1,12	0,86	0,91	1,29	47	14,25	13,41	3,70	9,66
19	1,19	0,10	0,06	0,16	48	12,25	10,95	1,24	6,75
20	0,12	0,32	0,36	0,36	49	13,16	12,50	2,77	5,95
21	0,44	1,80	1,85	2,19	50	12,95	12,41	2,64	6,23
22	0,78	2,40	2,45	2,71	51	13,4	8,67	1,08	2,89
23	0,25	0,78	0,82	1,49	52	13,57	12,37	12,37	12,37
24	1,74	1,61	1,66	1,88	53	12,51	11,63	11,63	11,47
25	1,17	1,39	1,44	2,05	54	4,35	2,10	2,10	3,54
26	7,86	7,20	7,20	0,16	55	2,45	1,89	1,89	2,91
27	3,98	4,66	4,66	0,18	56	1,52	0,49	0,49	0,05
28	3,84	3,43	3,43	0,23	57	3,33	1,35	1,35	0,60
29	2,66	2,97	2,97	0,64					

QUADRO 20 – TESTE 3 COM RNA DO TIPO ELMAN USANDO QUASE-NEWTON

Resultados estatísticos para o Teste 3 – Elman – quase-Newton				
Neurônios na camada oculta	2	4	5	10
Máximo (m)	16,46	16,79	16,79	12,37
Mínimo (m)	0,03	0,00	0,06	0,06
Média Aritmética (m)	4,8	4,19	3,25	3,22
Desvio Padrão (m)	5,12	4,25	3,68	3,21
RMS (m)	6,87	5,84	4,80	4,45
R^2	0,9948	0,9962	0,9974	0,9978
MAPE	0,42	0,37	0,29	0,28

QUADRO 21 – AVALIAÇÃO ESTATÍSTICA PARA O TESTE 3

Analisando-se os resultados através das RNAs verifica-se:

a) A escolha da arquitetura da RNA, do método de treinamento e dos neurônios nas camadas ocultas são fatores importantes e influenciam na resposta do modelo de tendência.

b) O teste 1 que apresenta a RNA – MLP, mediante o método de treinamento LM, apresenta variações significativas quando são modificados os neurônios na camada oculta. Nos testes realizados com 2 e 10 neurônios obteve-se desvios máximos respectivamente de 126,04 m e 242,08 m. Com 4 e 5 neurônios na camada oculta encontraram-se os melhores resultados para esse teste com desvio máximo em relação a linha de costa de controle de 16,46 m, para os dois casos, como exibido no QUADRO 17.

c) O teste 2, que apresenta a RNA – MLP e o método de treinamento Bayesiano com regularização, teve variações significativas quando modificado os números de neurônios nas camadas ocultas e o melhor resultado encontrado foi para 5 neurônios com as seguintes estatísticas, quando comparada com a linha de costa de controle (máximo valor; mínimo valor; média aritmética; desvio padrão; RMS; R^2 ; MAPE), (18,40 m; 0,02 m; 5,22 m; 5,61 m; 7,50 m; 99,38%; 0,46%). Os demais testes modificando o número de neurônios nas camadas ocultas apresentaram desvios muito altos com média acima de 38,13 m como pode ser observado no QUADRO 19.

d) Para o teste 3, com a rede de Elman, obteve-se pequenas variações quando são modificados os neurônios na camada oculta com o MAPE variando de 0,28% para 10 neurônios na camada oculta; 0,29% para 5; 0,37% para 4 e 0,42% para 2 conforme o QUADRO 21.

e) Os melhores resultados encontrados com as redes neurais foram os realizados com a RNA de Elman, com 10 neurônios na camada oculta e os com a MLP-LM, com 5 neurônios na camada oculta. Os dois métodos de treinamento testados apresentam os respectivos resultados (máximo valor; mínimo valor; média aritmética; desvio padrão; RMS; R^2 ; MAPE), (12,37 m; 0,06 m; 3,22 m; 3,21 m; 4,45 m; 99,78%; 0,28%) e (16,46 m; 0,04 m; 4,86 m; 5,10 m; 6,90 m; 99,47%; 0,43%).

4.1.3 Análise conjunta dos três modelos de tendência, selecionando o caso de melhor desempenho para cada um deles

O QUADRO 22 apresenta os melhores resultados para os três métodos de tendência: regressão linear (teste 3), estimativa robusta (teste 1) e redes neurais (teste RNA 3- Elman-quase-Newton; com 10 neurônios na camada oculta) comparando com os valores reais de GPS 2008 utilizados como controle para o conjunto de 57 amostras utilizadas no estudo. A segunda coluna do QUADRO 22 apresenta o número de iterações realizadas para a melhor solução da estimativa robusta.

Seções transversais	Número de iterações para melhor solução da estimativa robusta	Estimativa Robusta (GPS2008-Predição) Valor absoluto (m)	Regressão Linear (GPS2008-Predição) Valor absoluto (m)	Redes Neurais (GPS2008-Predição) Valor absoluto (m)					
(A)	(B)	(C)	(D)	(E)	(A)	(B)	(C)	(D)	(E)
1	12	0,85	0,91	3,96	30	3	0,12	2,06	0,06
2	13	1,36	0,94	3,30	31	3	0,69	1,21	1,10
3	28	1,01	4,23	5,44	32	2	1,18	1,69	0,73
4	1	1,31	2,12	0,51	33	2	3,01	1,57	10,38
5	14	0,90	2,57	2,90	34	2	2,15	2,89	2,18
6	3	0,93	0,71	2,33	35	5	0,30	5,80	0,13
7	1	0,29	0,53	1,94	36	7	6,00	1,86	10,14
8	20	0,47	3,32	5,07	37	19	0,36	5,52	0,06
9	2	2,13	3,09	3,98	38	3	0,36	10,48	7,12
10	2	0,45	1,47	3,12	39	1	1,57	3,01	1,20
11	27	2,24	2,34	1,55	40	3	0,07	3,16	0,39
12	2	0,68	3,14	0,49	41	1	4,21	6,74	1,84
13	2	0,81	2,67	0,84	42	3	1,46	1,73	2,56
14	2	1,58	4,36	2,02	43	1	4,77	5,35	2,32
15	2	0,23	2,9	2,18	44	5	0,01	2,29	1,05
16	2	1,76	5,59	4,40	45	1	6,73	11,38	4,78
17	2	0,23	3,10	1,63	46	1	6,21	11,97	10,41
18	1	1,61	6,25	1,29	47	1	0,73	0,29	9,66
19	1	0,79	6,59	0,16	48	3	0,28	3,82	6,75
20	1	1,60	5,25	0,36	49	2	1,97	1,59	5,95
21	1	0,78	4,08	2,19	50	2	0,28	2,68	6,23
22	1	1,24	3,92	2,71	51	2	0,68	1,55	2,89
23	1	0,32	3,86	1,49	52	1	7,63	8,66	12,37
24	1	1,29	2,91	1,88	53	2	2,36	4,45	11,47
25	1	1,24	3,11	2,05	54	1	0,27	2,01	3,54
26	2	0,06	0,05	0,16	55	3	0,04	3,39	2,91
27	21	0,50	3,78	0,18	56	1	1,20	2,94	0,05
28	4	0,45	2,85	0,23	57	7	6,20	8,84	0,60
29	4	0,70	2,70	0,64					

QUADRO 22 - RESÍDUOS OBTIDOS PARA 2008

Os valores do QUADRO 23 foram calculados a partir das equações (42) a (46) seguidos dos valores mínimos e máximos para os dados encontrados no QUADRO 22.

Cr�terio	Estimativa Robusta (m)	Regress�o Linear (m)	Redes Neurais (m)
M�ximo	7,63	11,97	12,37
M�nimo	0,01	0,05	0,06
M�dia Aritm�tica	1,56	3,57	3,22
Desvio Padr�o	1,83	2,57	3,21
RMS	2,39	4,48	4,45
R^2	0,9994	0,9978	0,9978
MAPE	0,14	0,33	0,28

QUADRO 23 – AVALIA  ES ESTAT STICAS PARA A TEND CIA DE 2008

Os resultados indicam que a estimativa robusta se ajusta melhor estatisticamente aos dados reais de 2008 utilizados como controle, sendo computados no QUADRO 23 os seguintes resultados (m dia aritm tica; desvio padr o; RMS; R^2 ; MAPE) como: (1,56 m; 1,83 m; 2,39 m; 99,94%; 0,14%) para estimativa robusta; (3,57 m; 2,57 m; 4,48 m; 99,78%; 0,33%) para regress o linear; e (3,22 m; 3,21 m; 4,45 m; 99,78%; 0,28%) para redes neurais.

Os maiores desvios em rela  o ao valor real formam 7,63 m para estimativa robusta, 11,97 m para regress o linear e 12,37 m para as redes neurais.

As FIGURAS 56, 57 e 58 representam os gr ficos dos desvios da linha de costa predita (2008) em rela  o aos valores utilizados como controle (GPS2008), estes gr ficos foram constru dos a partir dos dados do QUADRO 22 e foram separados em tr s para melhor visualiza  o em suas compara  es.

Nas FIGURAS 56 e 57 s o comparados os resultados encontrados para regress o linear e redes neurais, respectivamente, com os resultados encontrados para a estimativa robusta. Em ambos os casos visualiza-se uma melhora nos resultados usando o modelo de estimativa robusta onde os erros indicados em metros no eixo y est o abaixo da linha de 7 m (apenas um valor est  acima, no caso 7,63 m), conforme as amostras que aparecem no eixo x.




FIGURA 56 - COMPARAÇÃO ENTRE ESTIMATIVA ROBUSTA E REGRESSÃO LINEAR MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008

Na FIGURA 56 verificam-se as amostras que estão acima de 4 m de erro e para esta análise encontram-se as respectivas percentagens: 12% para estimativa robusta e 30% para regressão linear. No mesmo gráfico, observa-se que 5 amostras para o caso de regressão linear encontram-se acima de 8 m de erro.




FIGURA 57 - COMPARAÇÃO ENTRE ESTIMATIVA ROBUSTA E REDES NEURAIS MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008

Na FIGURA 57 é possível verificar que nas seções transversais 4, 12, 18, 19, 20, 27, 28, 29, 30, 32, 35, 37, 39, e 41 as RNAs mostraram melhores resultados. Porém, para os dois modelos neste conjunto de seções transversais encontram-se erros abaixo de 2 m. Valores acima de 8 m são visualizados neste gráfico para 5 casos referentes ao modelo de redes neurais, a saber 36, 46, 47, 52 e 53.

Ao comparar os resultados gráficos entre regressão linear e redes neurais artificiais mostrados, na FIGURA 58, verifica-se que em alguns casos as redes neurais apresentam resultados melhores (exemplos seções transversais 14, 18, 19, 20, 45, e 57) e em outros não (exemplos seções transversais 33, 36, 50 e 53), este fato ocorre, devido ao melhor ajuste do modelo poder variar conforme a seção transversal de estudo analisada. Ao analisar os erros que estão acima de 4 m encontram-se as seguintes percentagens: 30% para regressão linear e 23% para as redes neurais artificiais.




FIGURA 58 – COMPARAÇÃO ENTRE REGRESSÃO LINEAR E REDES NEURAIS MOSTRANDO A DIFERENÇA ABSOLUTA DA LINHA DE COSTA DE CONTROLE COM A PREDITA PARA O ANO DE 2008

4.2 OS RESULTADOS DE TENDÊNCIA POSICIONAL DA LINHA DE COSTA PARA O ANO 2055

O QUADRO 24 apresenta os valores das posições preditas para o ano de 2055, conforme o respectivo método: regressão linear (RL), estimativa robusta (ER) e redes neurais artificiais (RNA).

Seções	2055 RL	2055 ER	2055 RNA	Diferença 2055 Abs(RL-ER)	Diferença 2055 Abs(RL-RNA)	Diferença 2055 Abs(ER-RNA)							
transversais	(m)	(m)	(m)	(m)	(m)	(m)							
(A)	(B)	(C)	(D)	(E)	(F)	(G)	(A)	(B)	(C)	(D)	(E)	(F)	(G)
1	818,18	954,7	1014,08	136,52	195,9	59,38	30	1026,07	1046,99	1018,74	20,92	7,33	28,25
2	809,96	929,33	1012,96	119,37	203,00	83,63	31	1026,64	1049,56	1019,3	22,92	7,34	30,26
3	931,76	1006,51	1008,13	74,75	76,37	1,62	32	978,61	1027,37	1022,28	48,76	43,67	5,09
4	1005,65	1005,65	1015,54	0,00	9,89	9,89	33	930,57	986,28	1013,21	55,71	82,64	26,93
5	978,96	1021,8	1020,31	42,84	41,35	1,49	34	1100,76	1036,97	1016,83	63,79	83,93	20,14
6	932,66	1005,18	1017,63	72,52	84,97	12,45	35	1290,85	1042,02	1004,33	248,83	286,52	37,69
7	1018,03	1018,03	1021,98	0,00	3,95	3,95	36	1434,39	1015,54	1000,69	418,85	433,7	14,85
8	937,75	1005,13	1020,68	67,38	82,93	15,55	37	700,52	1042,61	1026,92	342,09	326,4	15,69
9	950,61	994,24	1023,03	43,63	72,42	28,79	38	1345,46	1210,91	1084,33	134,55	261,13	126,58
10	932,94	975,84	1021,72	42,9	88,78	45,88	39	1093,61	1093,61	1085,59	0,00	8,02	8,02
11	934,48	1033,53	1021,26	99,05	86,78	12,27	40	1140,57	1159,75	1174,17	19,18	33,6	14,42
12	942,64	1001,26	1020,05	58,62	77,41	18,79	41	1194,17	1194,17	1184,93	0,00	9,24	9,24
13	948,11	1006,12	1019,34	58,01	71,23	13,22	42	1150,15	1173,32	1180,63	23,17	30,48	7,31
14	967,39	1022,92	1021,23	55,53	53,84	1,69	43	1179,07	1179,07	1201,7	0,00	22,63	22,63
15	975,06	1029,66	1022,42	54,6	47,36	7,24	44	1511,01	1514,46	1611,24	3,45	100,23	96,78
16	964,14	1022,38	1024,75	58,24	60,61	2,37	45	1231,35	1231,35	1134,43	0,00	96,92	96,92
17	978,48	1034,33	1027,76	55,85	49,28	6,57	46	1238,63	1238,63	1130,17	0,00	108,46	108,46
18	1004,96	1004,96	1031,63	0,00	26,67	26,67	47	1217,72	1217,72	1186,74	0,00	30,98	30,98
19	1029,49	1029,49	1033,4	0,00	3,91	3,91	48	1162,25	1209,18	1316,06	46,93	153,81	106,88
20	1045,24	1045,24	1030,71	0,00	14,53	14,53	49	1201,91	1212,32	1258,09	10,41	56,18	45,77
21	1027,68	1027,68	1031,00	0,00	3,32	3,32	50	1205,13	1223,09	1162,95	17,96	42,18	60,14
22	1051,8	1051,8	1031,98	0,00	19,82	19,82	51	1194,13	1225,51	1191,23	31,38	2,9	34,28
23	1030,44	1030,44	1031,18	0,00	0,74	0,74	52	1228,41	1228,41	1183,97	0,00	44,44	44,44
24	1061,37	1061,37	1031,58	0,00	29,79	29,79	53	1318,52	1264,74	1184,43	53,78	134,09	80,31
25	1032,83	1032,83	1033,53	0,00	0,7	0,7	54	1198,94	1198,94	1183,64	0,00	15,3	15,3
26	1093,15	1062,11	1022,85	31,04	70,3	39,26	55	1206,57	1217,98	1183,91	11,41	22,66	34,07
27	1005,88	1054,49	1027,49	48,61	21,61	27,00	56	1200,15	1200,15	1183,62	0,00	16,53	16,53
28	995,8	1049,46	1025,32	53,66	29,52	24,14	57	1206,24	1217,55	1184,49	11,31	21,75	33,06
29	986,14	1040,94	1021,47	54,8	35,33	19,47							

QUADRO 24 – POSIÇÕES E DESVIOS DE LINHA DE COSTA PARA 2055

Com o objetivo de avaliar o comportamento dos modelos para uma predição a curto-prazo de 50 anos efetuou-se a comparação entre as posições preditas para 2055. No QUADRO 24 encontram-se as diferenças absolutas (abs) entre (RL-ER), (RL-RNA) e (ER-RNA).

O QUADRO 25 apresenta as avaliações estatísticas dos três métodos calculados no QUADRO 24, obtendo os seguintes resultados para média aritmética:

- 48,5 m na comparação entre (RL-ER);
- 71,1 m na comparação entre (RL-RNA); e
- 30,8 m na comparação entre (ER-RNA)

A máxima separação entre as linhas foi de 418,9 m entre (RL-ER); 433,7 entre (RL-RNA) e 126,6 m entre (ER-RNA).

Critério	Diferença 2055 Abs(RL-ER) (m)	Diferença 2055 Abs(RL-RNA) (m)	Diferença 2055 Abs(ER-RNA) (m)
Mínimo	0,00	0,70	0,70
Máximo	418,9	433,70	126,6
Média Aritmética	50,95	72,86	30,10
Desvio Padrão	79,36	86,83	30,94
RMS	92,05	110,80	42,49

QUADRO 25 – AVALIAÇÕES ESTATÍSTICAS ENTRE OS MODELOS DE TENDÊNCIA PARA O ANO DE 2055

Analisando as avaliações estatísticas, verifica-se que a escolha do modelo de tendência é fundamental. A comparação visual entre os modelos é mostrada na FIGURA 59, onde no eixo X está representada às seções transversais e no eixo Y a resposta para tendência do respectivo modelo para o ano de 2055.




FIGURA 59 – TENDÊNCIA DOS MODELO PARA O ANO DE 2055

4.3 RESTRIÇÃO PARA A LOCALIZAÇÃO DA “PEDRA” DE MATINHOS

Na FIGURA 60 é apresentada a tendência para a região da “pedra” de Matinhos. Nessa localidade acontece um condicionamento previsto no algoritmo para altitudes ortométricas acima de 4 m. Sendo assim, é possível observar nessa figura em azul tracejado a predição sem a restrição imposta para 2055, utilizando o método de estimativa robusta como exemplo; em amarelo a área com altitudes acima de 4 m; e em azul contínuo o contorno da “pedra” representado a posição da linha de costa.

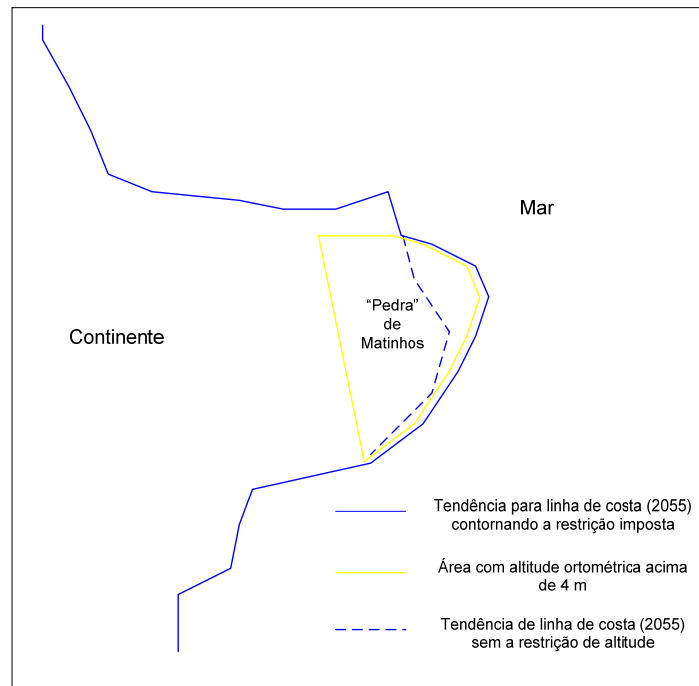


FIGURA 60 - RESTRIÇÃO PARA ALTITUDES ORTOMÉTRICAS ACIMA DE 4 m

4.4 TESTE COM DIFERENTES DISTÂNCIAS ENTRE AS SEÇÕES TRANSVERSAIS

Uma comparação com diferentes distâncias entre as seções transversais é apresentada na FIGURA 61. Neste caso, utilizou-se a distância fixa de 100 m e 25 m para efeitos de comparação. Quando se diminui o espaçamento entre as seções transversais aumenta-se a amostragem de seções e assim também o detalhamento da linha de costa como pode ser observado também na FIGURA 61.




FIGURA 61 - COMPARAÇÃO COM DIFERENTES ESPAÇAMENTOS DE SEÇÕES TRANSVERSAIS

4.5 FORMAÇÃO DO BANCO DE DADOS TEMPORAIS COM AS INFORMAÇÕES GEODÉSICAS

Como os resultados encontrados estão inseridos em um *software* de SIG, no caso o *Spring*, é possível manipular os dados organizados e efetuar medidas. Como exemplo dessas ferramentas disponíveis no sistema, selecionou-se as linhas de costa

de 1964, 2008 e a tendência pela estimativa robusta para 2055, calculando-se a distância euclidiana entre elas em uma determinada localidade da área de estudo. Os resultados desta comparação encontram-se na FIGURA 62.



FIGURA 62 - COMPARAÇÃO DA POSIÇÃO ENTRE DIFERENTES LINHAS DE COSTA TEMPORAIS

4.6 O MODELO MATEMÁTICO PARA LINHA DE COSTA

O modelo matemático utilizado para verificar a tendência da linha de costa utilizando a estimativa robusta e a regressão linear escolhido é um polinômio de primeira ordem EQUAÇÃO 9. Na literatura há indicação de que ele é o mais apropriado quando se trabalha com dados temporais da linha de costa. De acordo com Crowell *et al.* (1997) as previsões formuladas com polinômios de ordem maior podem obter resultados superiores que a regressão linear simples, porém, eles podem ser extremamente não-acurados para simulações futuras.

Um teste mudando o modelo matemático linear para o polinômio de segunda ordem, dado pela EQUAÇÃO 47;

$$\hat{y} = \hat{\beta}_1 x^2 + \hat{\beta}_2 x + \hat{\beta}_3, \quad (47)$$

foi efetuado para verificar o comportamento da predição a curto prazo, para o conjunto de dados do experimento de regressão linear com a matriz peso 3 que obteve diferenças entre o valor predito e o valor observado para o ano de 2008 maiores que 8 m. Sendo assim selecionaram-se as seguintes seções transversais apresentadas no QUADRO 27.

Para o teste com a Matriz peso 3 (regressão linear) valores > 8 m	
seção	(Predição2008-GPS2008) (m)
38	10,48
45	11,38
46	11,97
52	8,66
57	8,84

QUADRO 26 – SEÇÕES SELECIONADAS PARA O TESTE DE MUDANÇA DE MODELO MATEMÁTICO

A FIGURA 63 apresenta o resultado do ajustamento com os diferentes modelos polinomiais (primeira e segunda ordem), conforme o conjunto de dados da seção analisada.

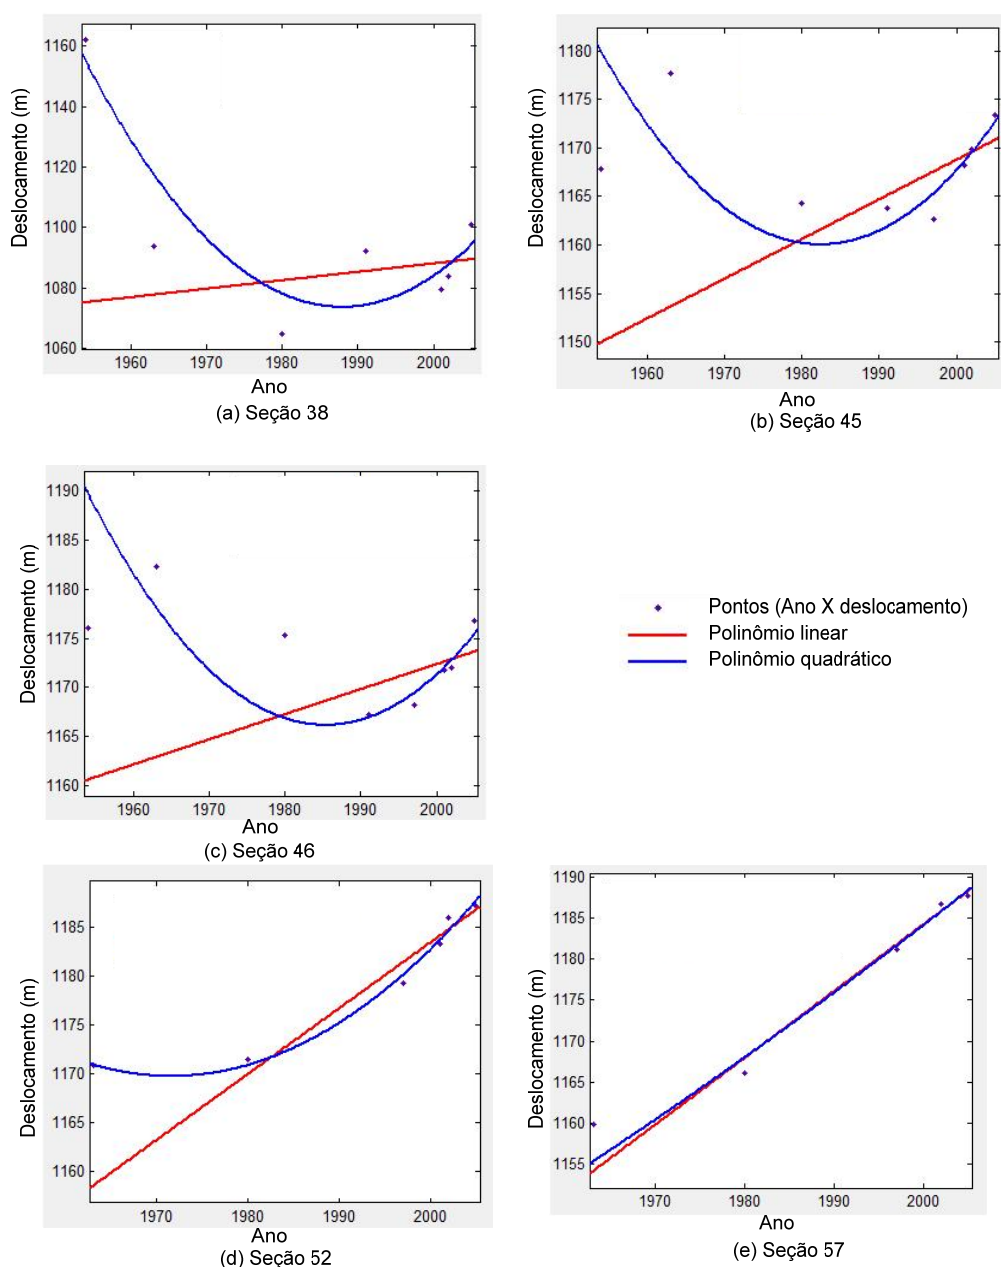


FIGURA 63 – TESTES COM OS MODELOS POLINÔMIAIS DE PRIMEIRA E SEGUNDA ORDEM PARA ALGUMAS SEÇÕES TRANSVERSAIS

O QUADRO 28 apresenta os resultados desta comparação.

	Modelo matemático linear				
	38	45	46	52	57
Erro de predição 2008 (m)	10,48	11,38	11,97	8,66	8,84
	Modelo matemático quadrático				
	6,91	1,26	1,4	6,36	9,05

QUADRO 27 – RESULTADOS PARA DIFERENTES MODELOS MATEMÁTICOS

Analisando os resultados visuais na FIGURA 62, verifica-se que o modelo polinomial quadrático, se ajusta melhor graficamente (conforme a curva representada por uma parábola neste modelo), que o modelo polinomial linear no conjunto de amostras temporais.

O QUADRO 28 apresenta o erro da predição de 2008, ou seja, a diferença entre a predição dos modelos para o ano de 2008, quando comparados com os dados de controle (GPS 2008) para as respectivas seções. Neste quadro é possível verificar uma melhoria para as seções 38, 45, 46, e 52, onde, por exemplo, na seção 45 e 46 o erro com o modelo linear é de aproximadamente 11 m. Ao aplicar o modelo quadrático, este erro mudou para aproximadamente 1 m. Porém, para a seção 57, este erro praticamente é o mesmo em torno de 9 m.

A escolha do modelo matemático é fundamental. Deve-se levar em conta, a quantidade de dados temporais e, neste caso, acredita-se que o modelo matemático linear é o mais adequado para esta situação.

Com o auxílio da FIGURA 64 tenta-se resumir a forma com que os métodos de predição foram trabalhados e apresentados nesta tese. Imagina-se que nesta ilustração o objetivo é atravessar de um ponto para outro com segurança. No caso 64 (a) apresenta-se um indivíduo atravessando sobre uma barra, onde ele está segurando, ao mesmo tempo, uma barra de equilíbrio e não existe nenhuma rede de proteção caso ocorra algum acidente, esta situação representa o método dos mínimos quadrados, aplicado no modelo de regressão linear que é dependente da distribuição normal dos dados. Nos experimentos, quando a matriz dos pesos é modificada, verifica-se a dependência do grau de confiança dos dados e do modelo matemático utilizado para o

modelo de predição. No caso 64 (b) é aplicado um determinado método de rejeição de erros grosseiros, onde o indivíduo, nesta situação, está atravessando o obstáculo na rede de segurança, porém rastejando. Nos experimentos com linha de costa, não se pensou em aplicar nenhuma rejeição de observações, pois a idéia foi trabalhar com todos os dados disponíveis tendo em vista a pouca quantidade de informações temporais. Em 64 (c), o indivíduo se encontra atravessando sobre uma ponte, segurando na barra, com uma rede de proteção, representando desta forma, a aplicação da estimativa robusta, ou seja, uma forma segura de trabalhar com os dados, e que apresentou os melhores resultados para a predição da posição de linha de costa, neste caso específico de estudo Já em 64 (d) o indivíduo atravessa uma linha, com uma rede de proteção (ou seja é possível configurar a RNA até encontrar uma resposta aceitável), usando um terno, o que indica uma forma alternativa de solucionar um problema, como, no caso, utilizando as redes neurais artificiais. A pasta preta que ele está segurando, representa a complexidade com que as redes neurais encontram suas soluções, na prática destaca-se que a inteligência computacional é uma alternativa para lidar com modelos de tendência.




FIGURA 64 – MODELOS DE TENDÊNCIA PARA LINHA DE COSTA
ADAPTADO DE: HAMPEL *et al.* (1986)

5 CONCLUSÕES E RECOMENDAÇÕES

A seguir são apresentadas as conclusões e recomendações desta tese.

5.1 CONCLUSÕES

Nesta tese foram organizados os dados históricos da linha de costa na área de estudo que compreende parte do município de Matinhos, no Paraná. Novas campanhas para obtenção da linha de costa foram realizadas no decorrer da pesquisa. No SIG costeiro organizado é possível criar mapas, manipular tabelas, efetuar medidas em relação às linhas de costa temporais e simular tendências, tornando-o um sistema atraente para gestores e administradores públicos.

Com as informações adquiridas e organizadas foi possível testar três modelagens de tendência. Uma forma de verificar o comportamento dos modelos de tendência foi testada para o ano de 2008. Os dados observados de 2008 foram retirados da modelagem para efeitos de comparação com os dados preditos para o mesmo ano.

O conjunto temporal de dados de entrada com informações da linha de costa normalmente são adquiridos por diversas fontes de mapeamentos, destaca-se assim, a importância de testar diferentes modelos de tendência capaz de manipular esses dados. Todos os modelos testados têm suas características próprias e ambos são fundamentais para fornecer uma tendência posicional da linha de costa.

A estimativa robusta, para este estudo de caso ofereceu estatisticamente a melhor possibilidade de elaborar uma modelagem preditiva a curto-prazo da posição de linha de costa. Esta situação foi apresentada no teste 1 onde a hipótese formulada foi em escolher como 2 vezes o erro reportado no processo de extração da linha de costa por Crowell *et al.* (1991), ou seja, 16 m para os pesos iniciais dos dados referentes ao mapeamento temporal resgatados da fotogrametria. Com a realização deste teste, quando comparado a tendência da linha de costa com a linha de costa de controle para o mesmo ano (GPS2008), obtiveram-se, os seguintes resultados (média aritmética;

desvio padrão; RMS; R^2 ; MAPE), (1,56 m; 1,83 m; 2,39 m; 99,94%; 0,14%), onde o resíduo máximo encontrado foi 7,63 m.

A característica principal da modelagem por estimativa robusta é atraente, pois os usuários não precisam apagar quaisquer porções que possam parecer erros grosseiros.

Foi também demonstrado que, para uma predição levando em conta um horizonte de tempo de 50 anos a previsão pode ser completamente dependente do modelo de tendência. Neste teste que simulou a posição da movimentação da linha de costa para o ano de 2055, foram encontrados diferenças de até 418 m quando comparado os modelos de regressão linear com o modelo de estimativa robusta. Ou seja, um erro de algumas dezenas de metros em uma tendência estimada para 2008, pode se propagar até centenas de metros para uma tendência mais distante, demonstrando a fundamental importância em considerar a escolha do modelo de tendência.

Destaca-se no processo de estimativa robusta:

1. Fornecer um método de gestão de *outliers* em modelos de tendência da linha de costa.
2. Proporcionar um diagnóstico e modelo de controle que pode ser utilizada para verificar a eficiência dos métodos tradicionais de tendência da linha de costa, como a regressão linear.

Os testes aplicando as RNAs iniciaram com a aplicação da MLP com o algoritmo de treinamento LM. Neste teste um fator importante que contribuiu para variação significativa dos resultados encontrados foi, a modificação dos neurônios na camada oculta, com 2 e 10 neurônios, resultados com erros acima de 100 metros em relação a posição de linha de costa de controle foram verificados. Ao modificar os neurônios para 4 e 5 na camada oculta, verificou-se os melhores resultados para esta arquitetura e treinamento da rede neural, encontrando, desta forma, o melhor resultado com 4

neurônios na camada oculta, que apresentou os seguintes resultados estatísticos (média aritmética; desvio padrão; RMS; R^2 ; MAPE), (3,69 m; 4,03 m; 5,36 m; 99,68%; 0,33%), onde o resíduo máximo encontrado foi 16,46 m.

O segundo teste com as redes neurais artificiais teve a intenção de modificar o algoritmo de treinamento para a arquitetura da MLP. Assim, optou-se por utilizar o treinamento Bayesiano com regularizações. Neste teste com 2, 4 e 10 neurônios nas camadas ocultas os resultados foram muito distantes da linha de controle. Porém, com 5 neurônios na camada oculta encontrou-se o resultado mais atrativo apresentando as seguintes estatísticas, (média aritmética; desvio padrão; RMS; R^2 ; MAPE), (5,22 m; 5,61 m; 7,50 m; 99,38%; 0,46%), onde o resíduo máximo encontrado foi 18,40 m.

No terceiro teste utilizando redes neurais artificiais foi utilizada uma nova arquitetura, no caso as redes de Elman. Para este caso, os melhores resultados encontrados foram com 10 neurônios na camada oculta e apresentaram as seguintes estatísticas, (média aritmética; desvio padrão; RMS; R^2 ; MAPE) , (3,22 m; 3,21 m; 4,45 m; 99,78%; 0,28%), com resíduo máximo de 12,37 m.

Tanto para as redes neurais artificiais (não supervisionada) quanto para aplicação do método dos mínimos quadrados (regressão linear e estimativa robusta) a abundância de dados é um fator desejável (BRAGA *et al.* (2000), citado na seção 2.6.3.2, página 72). Destacam-se dois problemas referentes à quantidade dos dados temporais que normalmente ocorrem com modelos de tendência para linha de costa:

1. Os dados são pobremente amostrados; e
2. Não existe uma regularidade entre os espaçamentos na aquisição dos dados temporais.

As duas situações encontradas foram decisivas para não aplicar novos modelos de estimativa de tendências de séries temporais, e aceitar como satisfatório os resultados encontrados pelos testes efetuados.

Mesmo levando-se em conta esses problemas citados anteriormente e as incertezas no processo de extração de linha de costa mediante documentos

cartográficos antigos, as redes neurais artificiais são uma alternativa, quando várias configurações são testadas em busca de um modelo de tendência para linha de costa.

Uma característica interessante observada nos experimentos se refere aos pesos das observações. Nos testes com a regressão linear, os pesos são extremamente importantes e a variação deles modifica diretamente o resultado encontrado, como pode ser visto nos testes 1, 2 e 3 onde, por exemplo, a estatística R^2 e MAPE variaram da seguinte forma (98,44%; 0,61%) para o teste 1, (99,56%; 0,41%) para o teste 2 e o melhor resultado foi encontrado no teste 3 com (99,78%; 0,33%).

Para a estimativa robusta, os pesos iniciais das linhas de costa temporais, já não são tão importantes quanto para regressão linear, pois a característica deste método é exatamente encontrar os melhores pesos em um processo iterativo, ou seja, mudando os pesos iniciais varia o resultado, porém, não tão significativamente como pode ser observado nas seguintes estatísticas R^2 e MAPE para os respectivos testes 1, 2 e 3 encontrando os respectivos resultados (99,94%; 0,14%); (99,89%; 0,17%) e (99,84%; 0,23%).

No caso das redes neurais artificiais, destaca-se que não existiu uma preocupação com os pesos nas observações, uma característica interessante, pois uma das questões da tese era descobrir se era possível encontrar uma solução satisfatória levando em conta a incerteza das observações temporais. Nesse aspecto à modelagem por redes neurais artificiais tem a capacidade de apresentar resultados sem levar em conta nenhum tipo de peso nos neurônios de entrada que contém os dados obtidos temporalmente de acordo com uma determinada técnica de mapeamento, no caso a Fotogrametria e os levantamentos geodésicos por GPS, pois ela não exige uma avaliação *a priori* das amostras.

A aplicação de uma restrição com informações sobre a topografia do terreno pode auxiliar na tendência da linha de costa como foi exemplificado no caso da “pedra” de Matinhos, criando assim regras que visam melhorar a modelagem.

A modelagem de tendência desenvolvida demonstrou ser um modelo flexível que pode ser aplicada para outras áreas de estudo.

Destaca-se que não se podem generalizar os resultados encontrados, pois estes representam e são válidos para este caso de estudo.

5.2 RECOMENDAÇÕES

Para o estudo e monitoramento da linha de costa em Matinhos recomenda-se dar continuidade em projetos que envolvam novos levantamentos geodésicos. O ideal seria o levantamento de dados mínimo anual na área de estudo, com o objetivo de acompanhar a evolução da erosão costeira e manter o banco de dados atualizado. Novas informações, além de aumentar as amostras temporais, contribuem diretamente no desempenho dos modelos preditivos.

Aplicar a metodologia de predição desenvolvida para uma nova área costeira de estudo. O LAGE possui dados referentes a Ilha do Mel no estado do Paraná, poderia pensar-se em organizar estes materiais temporais e construir um novo banco de dados temporais para a área da Ilha do Mel com a possibilidade de aplicar os modelos de tendência para esta nova região de estudo.

A modelagem de tendência com redes neurais é vista como um atrativo em modelos de predição. Suas características de buscar relacionamentos de diversas fontes de informações que podem ser incorporados aos dados de entrada são atraentes para a área costeira e para modelos de tendência da linha de costa. Seria interessante, se possível, colocar mais dados de entrada com diferentes variáveis para verificar o comportamento da RNA, por exemplo, dados referentes a variações climáticas temporais como: temperatura atmosférica, ventos, marés, pressão atmosférica, energia de ondas e variação no nível médio dos mares poderiam ser apresentados buscando um novo modelo para tendências costeiras.

REFERÊNCIAS

- ADDO, K. A.; WALKDEN, M.; MILLS, J. P. Detection, measurement and prediction of shoreline recession in Accra, Ghana. **Journal of Photogrammetry & Remote Sensing ISPRS**, n. 63, 2008. p. 543-558.
- ADUOL, F. W. O. Robust geodetic parameter estimation through iterative weighting. **Survey Review**, v. 32, n. 252, 1994. p. 359-367.
- ANGULO, R. J. Mapa do cenozóico do litoral do estado do Paraná. **Boletim Paranaense de Geociências**. Curitiba, Editora da UFPR, n. 55, 2004. p. 25-42.
- ANGULO, R. J.; SOARES, C. R. Beach profile variations between 1981 and 1993 in southern coast of Paraná state. **Boletim Paranaense de Geociências**, n. 42 Ed. UFPR, 1994. p. 203-216.
- ANGULO, R. J.; SOARES, C. R.; SOUZA, M. C. Excursion route along the state of Paraná (PR). In: 31 International Geological Congress. **Proceedings**. Rio de Janeiro, RJ, August 6-17, 2000. p. 58-81.
- ANGULO, R. J. Classificação da Costa Paranaense com base na sua Dinâmica, como Subsídio à Ocupação da Orla Litorânea. **Boletim Paranaense de Geociências**. Curitiba, Editora da UFPR, n. 44, 1996. p. 7-17.
- ANGULO, R. J. **A ocupação urbana do litoral paranaense e as variações da linha de costa**. Boletim Paranaense de Geociências, v. 41, 1993. p. 73-81.
- ARBIB, M. A. **The handbook of brain theory and neural networks**. Massachusetts Institute of Technology, 2003. 1309p.
- AWANGE, J. L.; ADUOL, F. W. O. An evaluation of some robust estimation techniques in the estimation of geodetic parameters. **Survey Review**, v. 35, n. 273, 1999. p.146-162.
- BABINSCK A. P. **Determinação da linha de costa por meio da monorestituição digital de imagens de câmaras de pequeno formato e técnicas GPS**. Dissertação (Mestrado) Programa de Pós-Graduação em Ciências Geodésicas - UFPR, Curitiba-PR. 2006.
- BIGARELLA, J. J. **Matinho: Homem e Terra - Reminiscências**. . Prefeitura Municipal de Matinhos, Associação de Defesa e Educação Ambiental, 1991.
- BIRD, E.C.F. **Beach management**. New York: John Wiley and Sons, 1996. 281p.

BOAK, E. H.; TURNER, I. L. Shoreline definition and detection: A review, **Journal of Coastal Research**, v. 21, n. 4, 2005. p. 688-703.

BRAGA, A. DE P.; CARVALHO A. P. DE L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. LTC - Livros Técnicos e Científicos Editora S.A., 2000. 262p.

CÂMARA, G.; SOUZA R. C. M.; FREITAS U. M.; GARRIDO J. SPRING: Integrating remote sensing and GIS by object-oriented data modeling. **Computers & Graphics**, v. 20, n. 3, 1996. p. 395-403.

CROWELL, M.; LETHERMAN, S. P.; BUCKLEY, M. K.; Historical shoreline change: error analysis and mapping accuracy. **Journal of Coastal Research**, v. 7, n. 3, 1991. p. 839-852.

CROWELL, M.; DOUGLAS, B. C.; LEATHERMAN S. P. On forecasting future U.S. shoreline positions: a test of algorithms. **Journal of Coastal Research**, v. 13, n. 4, 1997. p.1245-1255.

DALMOLIN, Q. **Ajustamento por mínimos quadrados**. 2^a. Edição/Quintino Dalmolin, Curitiba, 2004. 175p.

DEMAREST, J. M.; LEATHERMAN, S. P. Mainland influence on coastal transgression: Delmarva Peninsula. **Marine Geology**. n. 63, 1985. p. 19-33.

DIAMAT. Determinação do impacto ambiental decorrente da ação antrópica na linha costeira da região de Matinhos. **Relatório Técnico**. Coordenador: Prof. Dra. Cláudia Pereira Krueger. Universidade Federal do Paraná, 2000.

DOUGLAS, B. C.; CROWELL, M.; LEATHERMAN, S. P. Considerations for shoreline position prediction. **Journal of Coastal Research**, v. 14, n. 3, 1998. p. 1025-1033.

DOUGLAS, B. C.; CROWELL, M. Long-term shoreline position prediction and error propagation. **Journal of Coastal Research**, v. 16, n. 1, 2000. p. 145-152.

FLETCHER, R.; POWELL, M. J. D. A rapidly convergent descent method for minimization, **Computer Journal**, v. 7, 1963. p. 149-154.

FENSTER, M. S.; DOLAN, R.; ELDER, J. F. New method for predicting shoreline positions from historical data. **Journal of Coastal Research**, v. 9, n. 1, 1993. p. 147-171.

FENSTER, M. S.; DOLAN, R; MORTON, R. A. Coastal storms and shoreline change: Signal or noise? **Journal of Coastal Research**. v. 17, n. 3, 2000. p. 714-720.

FORESEE, F. D.; HAGAN, M. T. Gauss-Newton Approximation to Bayesian Regularization, **International Joint Conference on Neural Networks**, 1997. p. 1930-1935.

FUJII, S. Neural network signal processing for HF ocean radar. **International Geoscience and Remote Sensing Symposium of Earth Environment, IGARSS'93 Better Understanding of Earth Environment**, v. 1, 1993. p. 212-214.

GALGANO, F. A.; DOUGLAS, B. C.; LEATHERMAN, S. P. Trends and variability of shoreline position. **Journal of Coastal Research**. n. 26, 1998. p. 282-291.

GALGANO, F. A.; DOUGLAS, B. C. Shoreline Position Prediction: Methods and Errors. **Environmental Geosciences**. v. 7, n. 1, 2000. p. 1-10.

GEROMEL, L. H. **Aplicação de sistemas inteligentes em projetos de transformadores de potência**. Tese (Doutorado), Faculdade de Engenharia Elétrica e de Computação – UNICAMP, Campinas-SP. 2003. 144p.

GIBEAUT, J.C.; HEPNER T.; WALDINGER R.; ANDREWS J.; GUTIERREZ R.; TREMBLAY T. A.; SMYTH R.; XU L. **Changes in gulf shoreline position, Mustang, and North Padre Islands, Texas**. A report of the Texas Coastal Coordination Council pursuant to National Oceanic and Atmospheric Administration. Bureau of Economic Geology, The University of Texas, Austin Texas, 2001.

GIBEAUT, J.C. **Galveston Island Geohazards Map**. Bureau of Economic Geology Jackson School of Geosciences, The University of Texas at Austin, City of Galveston, 2007a. Comunicação pessoal disponível em : http://www.beg.utexas.edu/coastal/CSG_presentations.htm Acesso em: 17/05/2007.

GIBEAUT, J.C. **Impacts of Sea-level Rise, Erosion, Storms, and Development on the Barrier Islands of the Upper Texas Coast**. Bureau of Economic Geology Jackson School of Geosciences, The University of Texas at Austin, City of Galveston, 2007b. Comunicação pessoal disponível em : http://www.beg.utexas.edu/coastal/CSG_presentations.htm Acesso em: 17/05/2007.

GOLDFARB, D. A family of variable metric methods derived by variational means, **Mathematics of Computation**, v. 24, 1970. p. 23-26.

GONÇALVES, R. M.; KRUEGER, C. P.; HECK, B.; AWANGE, J.; CORTES, J. B. R. C. GPS assessment of shoreline extraction using high resolution images. In: 33rd International Symposium on Remote Sensing of Environment (ISRSE), **Proceedings** 2009, May 4-8 Stresa, Italy. 33rd International Symposium on Remote Sensing of Environment (ISRSE), 2009.

GORMAN, L.; MORANG, A.; LARSON, R.; Monitoring the coastal environment; Part IV: mapping, shoreline changes, and bathymetric analysis. **Journal of Coastal Research**, v. 14, n. 1, 1998. p. 61-92.

GUERRA F. A. **Análise de métodos de agrupamento para o treinamento de redes neurais de base radial aplicadas à identificação de sistemas.** Dissertação (Mestrado) Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PUC-PR, Curitiba-PR. 2006. 131p.

HAGAN, M. T.; MENHAJ M. B. Training feedforward networks with the Marquardt algorithm. **IEE Transactions on Neural Networks**, v. 5, n. 6, 1994. p. 989-993.

HAMPEL, F. R.; RONCHETTI, E. M., ROUSSEEUW P. J., STAHEL W. A. **Robust Statistics: The Approach Based on Influence Functions.** Wiley series in probability and statistics. John Wiley & Sons, Inc. 1986. 465p.

HAYATI, M.; SHIRVANY Y. Artificial neural network approach for short term load forecasting for Illam region. **World Academy of Science, Engineering and Technology**, n. 28, 2007. p. 280-284.

HAYKIN, S. **Neural networks – A comprehensive foundation.** McMaster University Hamilton, Ontario, Canada, Pearson Education, 1999. 823p.

HECKY, R. E.; NEWBURY, R. W.; BODALY, R. A.; PATALAS, K.; ROSENBERG, D. M.; Environmental impact prediction and assessment: the southern Indian lake experience. **Canadian Journal of Fisheries and Aquatic Sciences**, v. 41, n. 4, 1984. p.720-732.

HUBER, P. J. Robust estimation of a location parameter. **Annals of Mathematical Statistics**, n. 35, 1964. p. 73-101.

HUBER, P. J. **Robust Statistics.** John Wiley & Sons, New York, NY, USA. 1981.

IBGE - Instituto Brasileiro de Geografia e Estatística. Censo demográfico 2000. **Características da população e dos domicílios.** Resultados do universo. Rio de Janeiro-RJ: IBGE, 2001.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Estimativas populacionais para os municípios brasileiros.** Rio de Janeiro-RJ: IBGE, 2006.

KRÖSE B.; SMAGT P. V. D. **An introduction to neural networks.** The University of Amsterdam. 8th edition, 1996. 136p.

KRUEGER, C. P.; SOARES C. R.; PRADO, A. Monitoramento do Recuo e da Progradação da Linha de Costa Utilizando o Sistema de Posicionamento Global (GPS) In: COBRAC 98 – Congresso Brasileiro de Cadastro Técnico Multifinalitário, Florianópolis-SC, UFSC, **Proceedings**, 1998.

KRUEGER, C. P.; CENTENO, J. A.; MITISHITA, E. A.; VEIGA, L. A. K.; ZOCCOLLOTTI FILHO, C. A. J.; JUBANSKI, J.; URAKAWA, M. J. Determinacao da linha de costa na regioao de Matinhos. **Anais do Simpósio Brasileiro de Geomática**, Presidente Prudente – SP, 2002. p. 206-211.

KRUEGER, C. P.; GONÇALVES, R. M.; HECK, B. Surveys at the coast of Paraná, Brazil, to determinate the temporal coastal changes. **Journal of Coastal Research**, v. 1, 2009. p. 632-635.

KUBOTA, N.; HASHIMOTO, S.; KOJIMA, F. A sensory network for perception-based robotics using neural networks. **IEEE International Joint Conference on Neural Networks**, v. 4, 2003. p. 3151-3156.

LERA, G.; PINZOLAS M. Neighborhood based Levenberg-Marquardt algorithm for neural network training. **IEE Transactions on neural networks**, v. 13, n. 5, 2002. p. 1200-1203.

LI, R.; DI, K.; MA, R. A comparative study of shoreline mapping techniques. In: The 4th International Symposium on Computer Mapping and GIS for Coastal Zone Management, **Proceedings**, Nova Scotia, 2001. p. 18-20.

MAACK, R. **Geografia física do Estado do Paraná**. Curitiba, Banco BADEP, UFPR, IBPTB, 1968. 350p.

MACIEL, J. **Análise de um sistema de crédito cooperativo através de redes neurais (MLP) com a utilização do algoritmo Levenberg Marquardt**. Dissertação (Mestrado) Programa de Pós-Graduação em Métodos Numéricos em Engenharia – UFPR, 2005. 87p.

MACKAY, D. J. C. Bayesian interpolation, **Neural Computation**, v. 4, 1992. p. 415-447.

MAIA, R.; MAZUR S. **Dinâmica de linha de costa: mapeamento e monitoramento**. Trabalho de conclusão de curso (Graduação em Engenharia Cartográfica), UFPR, Curitiba-PR. 2008. 73p.

MENDEL, M.; MCLAREN, R. W. **Adaptive, Learning, and Pattern Recognition Systems: Theory and Applications**, chapter Reinforcement-learning control and pattern recognition systems, New York: Academic Press, 1970. p. 287-318.

METROPOLITAN BOROUGH OF SEFTON, 2002. **Shoreline monitoring annual report 2001/2002**. Disponível em: <http://www.sefton.gov.uk/pdf/TS_cdef_monitor_20012.pdf> Acesso em 14/11/2008.

MITISHITA, E. A. **Monorrestituição digital de fotos associada com sistema de computação gráfica CAD, para fins de mapeamento na área florestal**. Tese (Doutorado) Programa de Pós-Graduação em Engenharia Florestal - UFPR, Curitiba-PR. 1997.

MONTGOMERY, D. C.; RUNGER G. C.; HUBELE N. F. **Engineering Statistics**. 2nd Edition, John Wiley & Sons, Inc., 2001.

NEURAL NETWORK TOOLBOX, **The MathWorks™ - Accelerating the pace of engineering and science**. 2008. Comunicação do software Matlab disponível em: <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/index.html?/access/helpdesk/help/toolbox/nnet/function.html#9361> Acesso em: 05/06/2009

PEREIRA, B. B.; RAO C. R. **Data mining using neural networks a guide for statisticians**. June-2009, UERJ – Universidade Estadual do Rio de Janeiro e PSU-Penn State University. Comunicação pessoal disponível em : http://www.beg.utexas.edu/coastal/CSG_presentations.htm Acesso em: 17/05/2007

PIERRI, N.; ANGULO, R. J.; SOUZA, M. C.; KIM, M. K. **A ocupação e o uso do solo no litoral paranaense: condicionantes, conflitos e tendências**. Desenvolvimento e meio ambiente. Ocupação e uso do solo costeiro um mosaico de diversidade, editora UFPR, n. 13, 2006. p. 137-167.

PILKEY, O. H. **Costal erosion**. Episodes, v. 14, n.1, 1991. p. 46-51.

PILKEY, O. H.; THIELER, E. R. **Erosion of the United States shoreline**. Quaternary Coast of the United States: Marine and Lacustrine Systems, SEPM Special Publication, n. 48, 1992. 7p.

RIBEIRO, G. P. **Tecnologias digitais de geoprocessamento no suporte à análise espaço-temporal em ambiente costeiro**. Tese (Doutorado) Curso de Pós-Graduação em Geografia da Universidade Federal Fluminense – UFF, Rio de Janeiro-RJ, 2005.

RIBEIRO, S. R. A.. **Integração de imagens LANDSAT TM e dados auxiliares para a delimitação de unidades fisionômicas usando redes neurais artificiais**. Tese (Doutorado) Programa de Pós-Graduação em Ciências Geodésicas – UFPR, Curitiba-PR. 2003.

RUGGIERO, P.; CÔTÉ, J.; KAMINSKY G.; GELFENBAUM, G. Scales of Variability along the Columbia River Littoral Cell. **Proceedings of Coastal Sediments**, ASCE, 1999. p.1692-1707.

SCHAIBLE, B.; LEE, Y. C. Fuzzy logic models with improved accuracy and continuous differentiability. **IEEE Transactions on Components, Packaging, and Manufacturing Technology**, Part C, v. 19, n. 1, 1996. p. 37-47.

SCHIFF, K. C.; WEISBERG, S. B.; Microbiological monitoring of marine recreational waters in southern California. Environmental auditing. **Environmental Management**, v. 27, n. 1, 2001. p.149-157.

SHANNO, D. F. Conditioning of quasi-Newton methods for function minimization, **Mathematics of Computation**, v. 24, 1970. p. 145-160.

SOARES, C. R. Processos costeiros e erosão marinha. **Exame geral de qualificação de doutorado**. UNESP – Universidade Estadual Paulista, Curso de pós-graduação em Geociências, área de concentração em geociências e meio ambiente, Rio Claro-SP, 1995. 147p.

SOUZA, C. R. G. Coastal erosion and the coastal zone management challenges in Brazil. **Journal of Integrated Coastal Zone Management**. v. 9, n. 1, 2009. p. 17-37.

SOUZA, E. C. B. **Metodologia para modelagem do relevo oceânico usando redes neurais artificiais**. Tese (Doutorado) Programa de Pós-Graduação em Ciências Geodésicas – UFPR, Curitiba-PR. 2006. 208p.

SOUZA, E. C. B.; KRUEGER, C. P. Determinação das Variações Volumétricas Ocorridas no Istmo da Ilha do mel Utilizando o GPS. In: COBRAC2002 - Congresso Brasileiro de cadastro Técnico Multifinalitário, 2002, Florianópolis. **Anais do COBRAC2002 - Congresso Brasileiro de cadastro Técnico Multifinalitário**, v. 1, 2002. 1-12p.

SUGUIO, K. **Dicionário de geologia marinha**. T.A. Queiroz, São Paulo, SP, 1992. 171p.

TAN, G.; HUIMIN S.; WANG F.; DENG C. Short-term traffic flow prediction based on parallel quasi-Newton neural network, **International Conference on Measuring Technology and Mechatronics Automation**, v. 3, 2009. p. 305-308.

TANAJURA, E. L. X. **Investigações quanto aos parâmetros que influenciam no processamento de dados GPS visando a geração do MDT do Esporão Arenoso da Ilha do Mel**. Dissertação (Mestrado) Programa de Pós-Graduação em Ciências Geodésicas – UFPR, Curitiba-PR. 2008. 120p.

TEDESCO, A.; TEIXEIRA E. E.; LANDOVSKY S. G. **Uso das técnicas de posicionamento por satélites e sensoriamento remoto para monitoramento do impacto ambiental decorrente da ação antrópica na região de Matinhos (PR)**. Trabalho de conclusão de curso (Graduação em Engenharia Cartográfica), UFPR, Curitiba-PR. 2000. 141p.

VAFEIDIS, A. T.; KOUKOULAS, S.; GATSIS, I.; GKOLTSIU, K. Forecasting land-use changes with the use of neural networks and GIS, **Geoscience and Remote Sensing. IEEE International Symposium**, 2007. p. 5068-5071.

WALDEMARK, J.; DOVNER P. O.; KARLSSON J. Hybrid neural network pattern recognition system for satellite measurements. **IEEE International Conference on Neural Networks**, v. 1, n. 1, 1995. p. 195-199.

WANDRESEN, R. **Integração entre redes neurais e correlação para identificar pontos de apoio pré-sinalizados**. Tese (Doutorado) Programa de Pós-Graduação em Ciências Geodésicas – UFPR, Curitiba-PR. 2004. 141p.

WHITE, K.; ASMAR, E. L. Monitoring changing position of coastlines using thematic mapper imagery, an example from the Nile Delta. **Geomorphology**, v. 29, 1999. p. 93-105.

WINDROW, B.; HOFF M. E. Adaptative switching circuits. Institute of Radio Enginneers, **Western Electronic Show and Convention**, 1960 p. 96-104.

ZEFERINO, C. C. **Investigações de alguns métodos de posicionamento e receptores GPS na determinação das linhas de costa de Matinhos com uma análise temporal.** Trabalho de conclusão de curso (Graduação em Engenharia Cartográfica), UFPR, Curitiba-PR. 2007.